


د. تومي صالح  
أستاذ التعليم العالي  
كلية العلوم الاقتصادية وعلوم التسيير  
جامعة الجزائر

## مدخل

# لنظرية القياس الإقتصادي

دراسة نظرية مدعمة بأمثلة وتمارين

الجزء الأول  
الطبعة الثانية



ديوان المصطبوعات الجامعية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

الجامعة الوطنية للعلوم والتقنية

© ديوان المطبوعات الجامعية: 2011-01

رقم النشر: 4.01.4364

رقم ر.د.م.ك (ISBN): 978.9961.0.0350.3

رقم الإيداع القانوني: 1998-1050



**إلى  
والدتي  
زوجتي  
أبنائي  
و بناتي**

1/2

2/3

3/4

4/5

5/6

## مدخل لنظرية القياس الإقتصادي

### الجزء الأول:

الفصل الأول: التعريف والهدف من دراسة القياس الإقتصادي مع بعض المبادئ الإحصائية.

الفصل الثاني: تحليل نموذج الإنحدار الخطي البسيط.

الفصل الثالث: تحليل الإنحدار المتعدد.

الفصل الرابع: ميادين تطبيق الإنحدار المتعدد.

الفصل الخامس: نظرية العينات الكبيرة.

### الجزء الثاني:

الفصل السادس: طريقة المربعات الصغرى المعممة، ومشاكل تطبيق الإنحدار المتعدد.

الفصل السابع: المتغيرات المؤخرة ونماذج توزيع التأخير.

الفصل الثامن: نماذج السلاسل الزمنية.

الفصل التاسع: مدخل لنظام معادلات خطية.

الملحق.

# البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

البيان

# الجزء الأول

1991-1992

## مقدمة المؤلف

"إن القياس الإقتصادي هو فن و علم إستعمال الطرق الإحصائية لغرض قياس العلاقات الإقتصادية. حيث تستعمل طرق القياس الإقتصادي لتقدير معالم النموذج، اختبار الفرضيات الموضوعية حول النموذج، و تعميم التنبؤات من هذا الأخير. فبناء نموذج القياس الإقتصادي يعتبر فنا، تماما، مثلما نستعمل معلومات الهندسة المعمارية لتهيئة البنايات" GREGORY . C . CHOW 1983 .

أخي الطالب:

إن الغرض من إصدار هذا المرجع هو إعطاء بعض التقنيات المستعملة في تقدير وبناء نماذج القياس الإقتصادي البسيطة و الخطية. مع العلم أن هناك جزءا ثانيا مكمل لهذا الكتاب ، حيث يعتبر هذا الأخير، من خلال طبعته الأولى، تنسيقا للمحاضرات التي ألقيتها منذ سنة 1987 إلى يومنا هذا، على طلبة السنة الثالثة لبعض التخصصات ( القياس الإقتصادي، التحليل الإقتصادي، والتخطيط والتنمية الإقتصادية ) بمعهد العلوم الإقتصادية لجامعة الجزائر. وقد راعيت أن تشمل مادة هذا الكتاب الموضوعات المناسبة لطلبة المعاهد الوطنية العليا المتخصصة في الإحصاء والإقتصاد التطبيقي . أملي، بعد إستعمال هذا الكتاب في شكله الحالي، أن تصلني إقتراحات وإنتقادات القراء البناء لغرض تحسينه في طبعته القادمة.

في الأخير أجد نفسي مدينا للأستاذة زكية بلعربي على مساعدتي في تنقيح النسخة الأولى لهذا العمل، والأستاذ علي رعاد على إثرائه لهذه النسخة من الناحية العلمية واللغوية إثر تكليفه من طرف المجلس العلمي لمعهد العلوم الإقتصادية بهذا الغرض. كما لا أنسى شكري للأستاذة حورية دابوز عما قدمته من جهد في طباعة هذه المادة ولالأستاذ محمد عبدالمؤمن ، (رئيس مركز الإعلام الآلي)، على مساعدتي في وضع اللمسات الأخيرة والإخراج النهائي لهذه النسخة . ولا بد من التذكير بأن كل النقائص الممكن ظهورها يتحملها المؤلف .

صالح تومي

معهد العلوم الإقتصادية - جامعة الجزائر -

جانفي 1997 .

المجلس الأعلى

العلمية والبحثية

في إطار الميثاق الوطني للبحث العلمي، الذي يهدف إلى تعزيز البحث العلمي في الجزائر.

والمجلس الأعلى للدراسات والبحوث، الذي يهدف إلى تعزيز الدراسات والبحوث في الجزائر.

والمجلس الأعلى للتعليم، الذي يهدف إلى تعزيز التعليم في الجزائر.

والمجلس الأعلى للصحة، الذي يهدف إلى تعزيز الصحة في الجزائر.

والمجلس الأعلى للثقافة، الذي يهدف إلى تعزيز الثقافة في الجزائر.

والمجلس الأعلى

للبيئة، الذي يهدف إلى تعزيز البيئة في الجزائر.

والمجلس الأعلى للمياه، الذي يهدف إلى تعزيز المياه في الجزائر.

والمجلس الأعلى للغذاء، الذي يهدف إلى تعزيز الغذاء في الجزائر.

والمجلس الأعلى للتكنولوجيا، الذي يهدف إلى تعزيز التكنولوجيا في الجزائر.

والمجلس الأعلى للسياحة، الذي يهدف إلى تعزيز السياحة في الجزائر.

والمجلس الأعلى للتجارة، الذي يهدف إلى تعزيز التجارة في الجزائر.

والمجلس الأعلى للصناعة، الذي يهدف إلى تعزيز الصناعة في الجزائر.

والمجلس الأعلى للزراعة، الذي يهدف إلى تعزيز الزراعة في الجزائر.

والمجلس الأعلى للثروة الحيوانية، الذي يهدف إلى تعزيز الثروة الحيوانية في الجزائر.

والمجلس الأعلى للصيد، الذي يهدف إلى تعزيز الصيد في الجزائر.

والمجلس الأعلى للسياحة، الذي يهدف إلى تعزيز السياحة في الجزائر.

والمجلس الأعلى للتجارة، الذي يهدف إلى تعزيز التجارة في الجزائر.

والمجلس الأعلى للصناعة، الذي يهدف إلى تعزيز الصناعة في الجزائر.

والمجلس الأعلى للزراعة، الذي يهدف إلى تعزيز الزراعة في الجزائر.

والمجلس الأعلى للثروة الحيوانية، الذي يهدف إلى تعزيز الثروة الحيوانية في الجزائر.

والمجلس الأعلى للصيد، الذي يهدف إلى تعزيز الصيد في الجزائر.

والمجلس الأعلى للسياحة، الذي يهدف إلى تعزيز السياحة في الجزائر.

والمجلس الأعلى للتجارة، الذي يهدف إلى تعزيز التجارة في الجزائر.

والمجلس الأعلى للصناعة، الذي يهدف إلى تعزيز الصناعة في الجزائر.

والمجلس الأعلى للزراعة، الذي يهدف إلى تعزيز الزراعة في الجزائر.

والمجلس الأعلى للثروة الحيوانية، الذي يهدف إلى تعزيز الثروة الحيوانية في الجزائر.

والمجلس الأعلى للصيد، الذي يهدف إلى تعزيز الصيد في الجزائر.



## الفهرس

### الصفحة

### الموضوع

#### الفصل الأول: التعريف والهدف من دراسة القياس الإقتصادي مع بعض

1	المبادئ الإحصائية
1-1	تعريف القياس الإقتصادي
2-1	النموذج الإقتصادي ونموذج القياس الإقتصادي
3-1	أهداف ومناهج البحث في القياس الإقتصادي
1-3-1	أهداف القياس الإقتصادي
2-3-1	مراحل البحث في القياس الإقتصادي
1-4	بعض المبادئ الإحصائية
1-4-1	خصائص التوقع الرياضي
2-4-1	المتغيرات العشوائية والتوزيعات الاحتمالية
3-4-1	تعريف المقدّر
4-4-1	طرق التقدير
5-4-1	خصائص المقدرات
5-1	سلسلة تمارين حول الفصل الأول

#### الفصل الثاني: نموذج الإنحدار الخطي البسيط

1-2	نموذج الإنحدار
2-2	طريقة المربعات الصغرى
3-2	الفرضيات الكلاسيكية للنموذج
4-2	خصائص مقدرات المربعات الصغرى
1-4-2	خاصية عدم التحيز

## الصفحة

## الموضوع

41	2-4-2 خاصية الكفاءة
42	3-4-2 أفضل مقدر خطي غير متحيز
45	4-4-2 خاصية الإتساق
48	5-2 الإختبارات الإحصائية حول مغنوية المعالم
49	1-5-2 إختبار جودة التوفيق
51	2-5-2 توزيعات المعاينة لمقدرات المربعات الصغرى
53	3-5-2 إختبار التوزيع Student-t
54	4-5-2 مجال الثقة لمعالم الإنحدار
56	5-5-2 إختبار الفرضيات
59	6-5-2 إختبار التوزيع Fischer- F
61	6-2 التقدير بطريقة المعقولية العظمى
65	7-2 التنبؤ
69	8-2 أخطاء في المتغيرات
74	9-2 مثال (1.2)
78	10-2 سلسلة تمارين حول الفصل الثاني
85	<b>الفصل الثالث: تحليل الإنحدار المتعدد</b>
85	1-3 نموذج إنحدار بمتغيرين مستقلين
86	- المعادلات الطبيعية للنموذج
90	2-3 توسيع النموذج إلى k متغير مستقل
92	- حساب معامل التحديد المضاعف
95	3-3 النموذج الخطي العام
99	4-3 الخصائص الإحصائية لمقدرات المربعات الصغرى
106	5-3 الإستنباط الإحصائي لمقدرات المربعات الصغرى

## الصفحة

## الموضوع

115	6-3 الإتحاد المجزأ
117	7-3 مثال (2.3)
120	8-3 سلسلة تمارين حول الفصل الثالث
126	<b>الفصل الرابع: ميادين تطبيق الإتحاد المتعدد</b>
126	1-4 إضافة متغيرات للإتحاد
130	1-1-4 النتائج الإحصائية
131	2-1-4 الحذف غير الصحيح لمحدرات
133	3-1-4 الإضافة غير الصحيحة لمحدرات
133	4-1-4 اختبار فرضية العدم
135	2-4 تقدير القيود الخطية
135	1-2-4 تقنية التعويض
137	2-2-4 اختبار مجموعة قيود خطية
138	3-2-4 اختبار القيود الفردية
139	4-2-4 تقنية مضاعفات لأقرا
145	3-4 التنبؤ في ظل النموذج الخطي العام
153	4-4 اختبارات التغير الهيكلي
153	1-4-4 اختبار التغير الهيكلي لنموذج بسيط
162	2-4-4 اختبار التغير الهيكلي لـ $k$ متغير مستقل
164	5-4 المتغيرات الوهمية
165	1-5-4 تغير الحد الثابت
168	2-5-4 اختلاف الميل وعدم تغير الحد الثابت
169	3-5-4 الحالة التوفيقية
173	4-5-4 المتغيرات الوهمية كمتغيرات مستقلة وحيدة



## الصفحة

## الموضوع

175	5-5-4 المتغير الوهمي كمتغير تابع
177	6-5-4 استعمال المتغيرات الوهمية للتعديل الموسمي
181	6-4 التعدد الخطي
185	1-6-4 اختبارات إكتشاف التعدد الخطي
191	2-6-4 الحلول المقترحة للتعدد الخطي
192	3-6-4 مثال (1.4)
196	4-6-4 مثال (2.4)
199	7-4 سلسلة تمارين حول الفصل الرابع

## الفصل الخامس: نظرية العينات الكبيرة

206	1-5 نظريات النهاية
207	1-1-5 نظرية BERNOULI
209	2-1-5 التقارب بالإحتمال
211	3-1-5 نظرية KHINTCHINE
212	4-1-5 قاعدة CHEBYSHEV
214	5-1-5 التقارب بالإحتمال إلى متغير عشوائي
214	6-1-5 التقارب الدائم والمؤكد
215	7-1-5 نظرية KOLMOGOROV
217	8-1-5 التقارب بالتوزيع
220	9-1-5 نظرية النهاية المركزية
222	10-1-5 خصائص التقارب بالإحتمال والتقارب بالتوزيع
224	2-5 المربعات الصغرى في العينات الكبيرة
225	1-2-5 إتساق مقدر تباين الأخطاء
226	2-2-5 توزيع $\hat{\beta}$ في العينات الكبيرة

## الصفحة

## الموضوع

228	3-2-5 القيود الخطية الدقيقة
229	4-2-5 إتساق $\hat{\beta}$ لما تكون المصفوفة X عشوائية
230	3-5 التوزيعات التقاربية لمقدر المعقولية العظمى
230	1-3-5 طريقة المعقولية العظمى
232	2-3-5 الشروط النظامية
236	3-3-5 اشتقاق مترابطة Cramer-Rao
241	4-3-5 الخصائص التقاربية لمقدر المعقولية العظمى
246	5-3-5 مقدر المعقولية العظمى المقيد
254	4-5 إجراء الاختبارات التقاربية
255	1-4-5 اختبار Wald
256	2-4-5 اختبار نسبة المعقولية
257	3-4-5 اختبار مضاعف لاقرانج
259	5-5 التقدير بالمتغيرات الأدواتية
262	1-5-5 الخصائص الإحصائية لمقدر المتغيرات الأدواتية
264	2-5-5 حساب بواقي المتغيرات الأدواتية
265	3-5-5 القيود الخطية الصحيحة
266	4-5-5 حساب الاختبارات الإحصائية لما $R\beta = r$
268	6-5 سنسنة تمارين حول الفصل الخامس
275	ملحق الجداول الإحصائية
293	قائمة المراجع





# الفصل الأول: التعريف والهدف من دراسة القياس الاقتصادي مع بعض المبادئ الإحصائية.

## 1-1 تعريف القياس الاقتصادي

يعتبر القياس الاقتصادي فرعاً من فروع علم الاقتصاد. حيث يهتم بالقياس والتقدير الميداني للعلاقات الاقتصادية.

يعتبر هذا التعريف شاملاً، حيث أن كل العلاقات الاقتصادية تهتم بالقياس. إذ أننا نقيس، عادة، الإنتاج الوطني الخام، حجم البطالة، التوظيف، عرض النقود والطلب عليها، الصادرات والواردات، مؤشرات الأسعار وغيرها. ويعرف الباحث<sup>(1)</sup> Maddala القياس الاقتصادي على أنه: "تطبيق طرق الإحصاء والرياضيات في تحليل المعطيات الاقتصادية، لهدف التأكد الميداني من النظريات الاقتصادية و من ثم قبولها أو رفضها".

و منه فإن القياس الاقتصادي يختلف عن الرياضيات الاقتصادية التي تعني تطبيق الرياضيات على تلك العلاقات الاقتصادية دون التأكد من صحة تلك العلاقات ميدانياً. و يعتبر القياس الاقتصادي أداة توفيقية ما بين النظرية الاقتصادية، الرياضيات الاقتصادية والإحصاء. لكنه يختلف تماماً عن كل هذه الفروع. و يعتمد باحثو القياس الاقتصادي على مبادئ النظرية الاقتصادية عند بنائهم لنموذج القياس الاقتصادي Econometric Model، مستعملين النظرية الإحصائية وتقنيات القياس الاقتصادي. و من ثم يختبرون، ميدانياً، بعض العلاقات الموجودة فيما بين المتغيرات الاقتصادية، و يمكن تطبيق القياس الاقتصادي على عدة ميادين مثل العلوم الاجتماعية والإنسانية، الصحة، النقل وغيرها.

<sup>1</sup>- G.S MADDALA "Introduction to Econometrics" Mac.Millan publishing Company, Chap 1, U.S.A, 1988.

إن أول ظهور للقياس الإقتصادي جاء مع إنشاء جمعية القياس الإقتصادي Econometric Society المكونة سنة 1930، و من ثم إصدار المجلة الدورية Econometrica سنة 1933. تبعته، بعد ذلك، عدة دوريات أخرى متخصصة في هذا الميدان مثل مجلة القياس الإقتصادي Journal of Econometrics و غيرها. لبناء أي نموذج قياس إقتصادي، نبدأ عادة بنظرية العلاقات الإقتصادية، حتى نقيس و نحدد الصياغة الرياضية للنموذج (بناء النموذج). و منه نستعمل طرقاً مناسبة (طرق التقدير في القياس الإقتصادي) للحصول على مقدرات عددية لمعالم العلاقات الإقتصادية (المرونة، المضاعفات، الأميال، التكاليف الحدية، المعاملات التقنية و غيرها).

إن أهم ميزة في نموذج القياس الإقتصادي للعلاقات الإقتصادية هو أنه يحتوي على الحد العشوائي (عنصر الخطأ) الذي يخضع لقوانين الاحتمال، و الذي نجده مهماً لدى النظرية الإقتصادية و الرياضيات الإقتصادية. إذ يعطي هذا المتغير العشوائي (الحد العشوائي أو عنصر الخطأ) العلاقات الصحيحة و الدقيقة للظواهر والعلاقات الإقتصادية فيما بينها.

## 1-2 النموذج الإقتصادي ونموذج القياس الإقتصادي

إن أول مشكلة تواجه باحث القياس الإقتصادي هي تشكيل نموذج القياس الإقتصادي. و منه نعرف النموذج على أنه تمثيل مبسط لعدة علاقات إقتصادية معقدة. فمثلاً لما نقول أن الكمية المطلوبة من الحمضيات هي دالة لسعر هذه الأخيرة، فإننا نقوم بتمثيل هذه العلاقة بأبسط ما يمكن. حيث، ميدانياً، توجد عدة متغيرات إقتصادية و غير إقتصادية أخرى تتحكم في الطلب على الحمضيات مثل دخل المستهلكين، أسعار السلع البديلة، أذواق المستهلكين. عادات و تقاليد المجتمع المعني بالدراسة و غيرها.



هناك علماء إقتصاد كثيرون يشجعون هذا التبسيط. لأن النماذج البسيطة سهلة الفهم، وبتوفر البيانات (المعطيات) يمكن اختبارها. ويتزعم هذا الفريق من الباحثين الإقتصاديين كلا من Karl Propper 1959 و الإقتصادي المشهور Milton Friedman 1953. ومع هذا التبسيط لشرح العلاقات الإقتصادية المعقدة، نلاحظ أن النموذج مبسط أكثر من اللزوم أولاً، و الفرضيات الموضوعية حول النموذج ليست دائماً محققة ثانياً.

ولتخاشي العيب الأول، يرى الباحث Koopmans 1957 أنه يمكننا الإنطلاق من النموذج المبسط، ثم ننقل تدريجياً إلى نماذج معقدة أكثر. من جهة أخرى، يرى باحثون آخرون أننا ننطلق من نموذج عام يحتوى كل المتغيرات الإقتصادية الممكنة، ثم نبسطه تبعاً للمعطيات المتوفرة لدينا. أما بالنسبة للعيب الثاني، فإن الإقتصادي M. Friedman يرى بأن فرضيات أية نظرية لا يمكن أن تكون دائماً محققة، و يؤيده في ذلك باحثو القياس الإقتصادي المشهورين أمثال J.D. Sargan، و الأستاذ D.F. Hendry.

عملياً، ندخل كل المتغيرات الإقتصادية التي نظن أن لها علاقة سببية قوية في بناء النموذج. أما بقية المتغيرات التي لا نعرفها (أو لا تتوفر لدينا عنها بيانات إحصائية) فنضعها في متغير واحد ونسميه بمتغير الخطأ العشوائي (عنصر الخطأ). وهذا التصرف يؤدي بنا إلى التفريق ما بين النموذج الإقتصادي ونموذج القياس الإقتصادي. فالنموذج الإقتصادي هو عبارة عن مجموعة من الفرضيات التي تشرح (بالتقريب) تصرف إقتصاد بلد ما، أو قطاع إقتصادي معين.

أما نموذج القياس الإقتصادي فيحتوي على مايلي:

- (1) مجموعة معادلات سلوكية (تصرفية) أو تقنيّة، مشتقة من النموذج الإقتصادي. تحتوي هذه المعادلات على بعض المتغيرات المشاهدة والبعض الآخر غير مشاهدة نكتبه في شكل متغير عشوائي هو "عنصر الخطأ"
- (2) تقرير مفصل حول ما إذا كانت هناك أخطاء في قياس ملاحظات المتغيرات المشاهدة.

(3) تخصيص توزيع احتمالي لهذه الأخطاء العشوائية (و أخطاء القياس)  
فإذا أخذنا النموذج المبسط للطلب على الحمضيات مثلا، فإن نموذج القياس  
الإقتصادي يحتوي، عادة، على ما يلي:

(a) المعادلة السلوكية (التصرفية) وهي:  $q = \alpha + \beta P + u$

حيث أن:  $q$  هي الكمية المطلوبة من الحمضيات،  $P$  هي سعر الحمضيات  
و  $\alpha$ ،  $\beta$  هما معلمتان غير معروفتين.

و تمثل، هنا،  $q$ ،  $P$  المتغيرين المشاهدين. أما  $u$  فهو المتغير العشوائي غير  
المشاهد.

(b) تخصيص التوزيع الإحصائي لعنصر الخطأ  $u$  والذي نفترض أنه يحقق الشرط  
 $E(u/P) = 0$ . كما أن قيم  $u$  مستقلة من أجل كل الملاحظات المختلفة و الموزعة  
طبيعيا كما يلي  
$$u \sim IN(0, \sigma_u^2)$$

إن بمساعدة هذه التخصيصات، يمكننا إختبار، ميدانيا، قانون الطلب أو  
الفرضية المنبثقة من النظرية الإقتصادية والتي تقول يجب أن يكون  $\beta < 0$ . كما  
يمكننا استعمال القيم المقدرة للمعلمتين  $\alpha$ ،  $\beta$  (مستعملين طرق التقدير التي سيأتي  
ذكرها فيما بعد) لدالة الطلب المقدرة من أجل التنبؤ بالكميات المطلوبة مستقبلا، أو  
من أجل أهداف إقتصادية وسياسية أخرى.



## 1-3 أهداف ومناهج البحث في القياس الإقتصادي

### 1-3-1 أهداف القياس الإقتصادي

هناك ثلاثة أهداف رئيسية لموضوع القياس الإقتصادي. حيث يهدف هذا الأخير إلى:

(1) بناء النماذج القياسية الإقتصادية، أي بناء النماذج الإقتصادية في شكل قابل للاختبار الميداني. وهناك عدة طرق لبناء نموذج القياس الإقتصادي من النموذج الإقتصادي عن طريق اختيار الشكل الدالي، تخصيص الهيكل العشوائي للمتغيرات، وهكذا. وتمثل هذه المرحلة مشكلة تصور الصياغة الرياضية في منهجية القياس الإقتصادي.

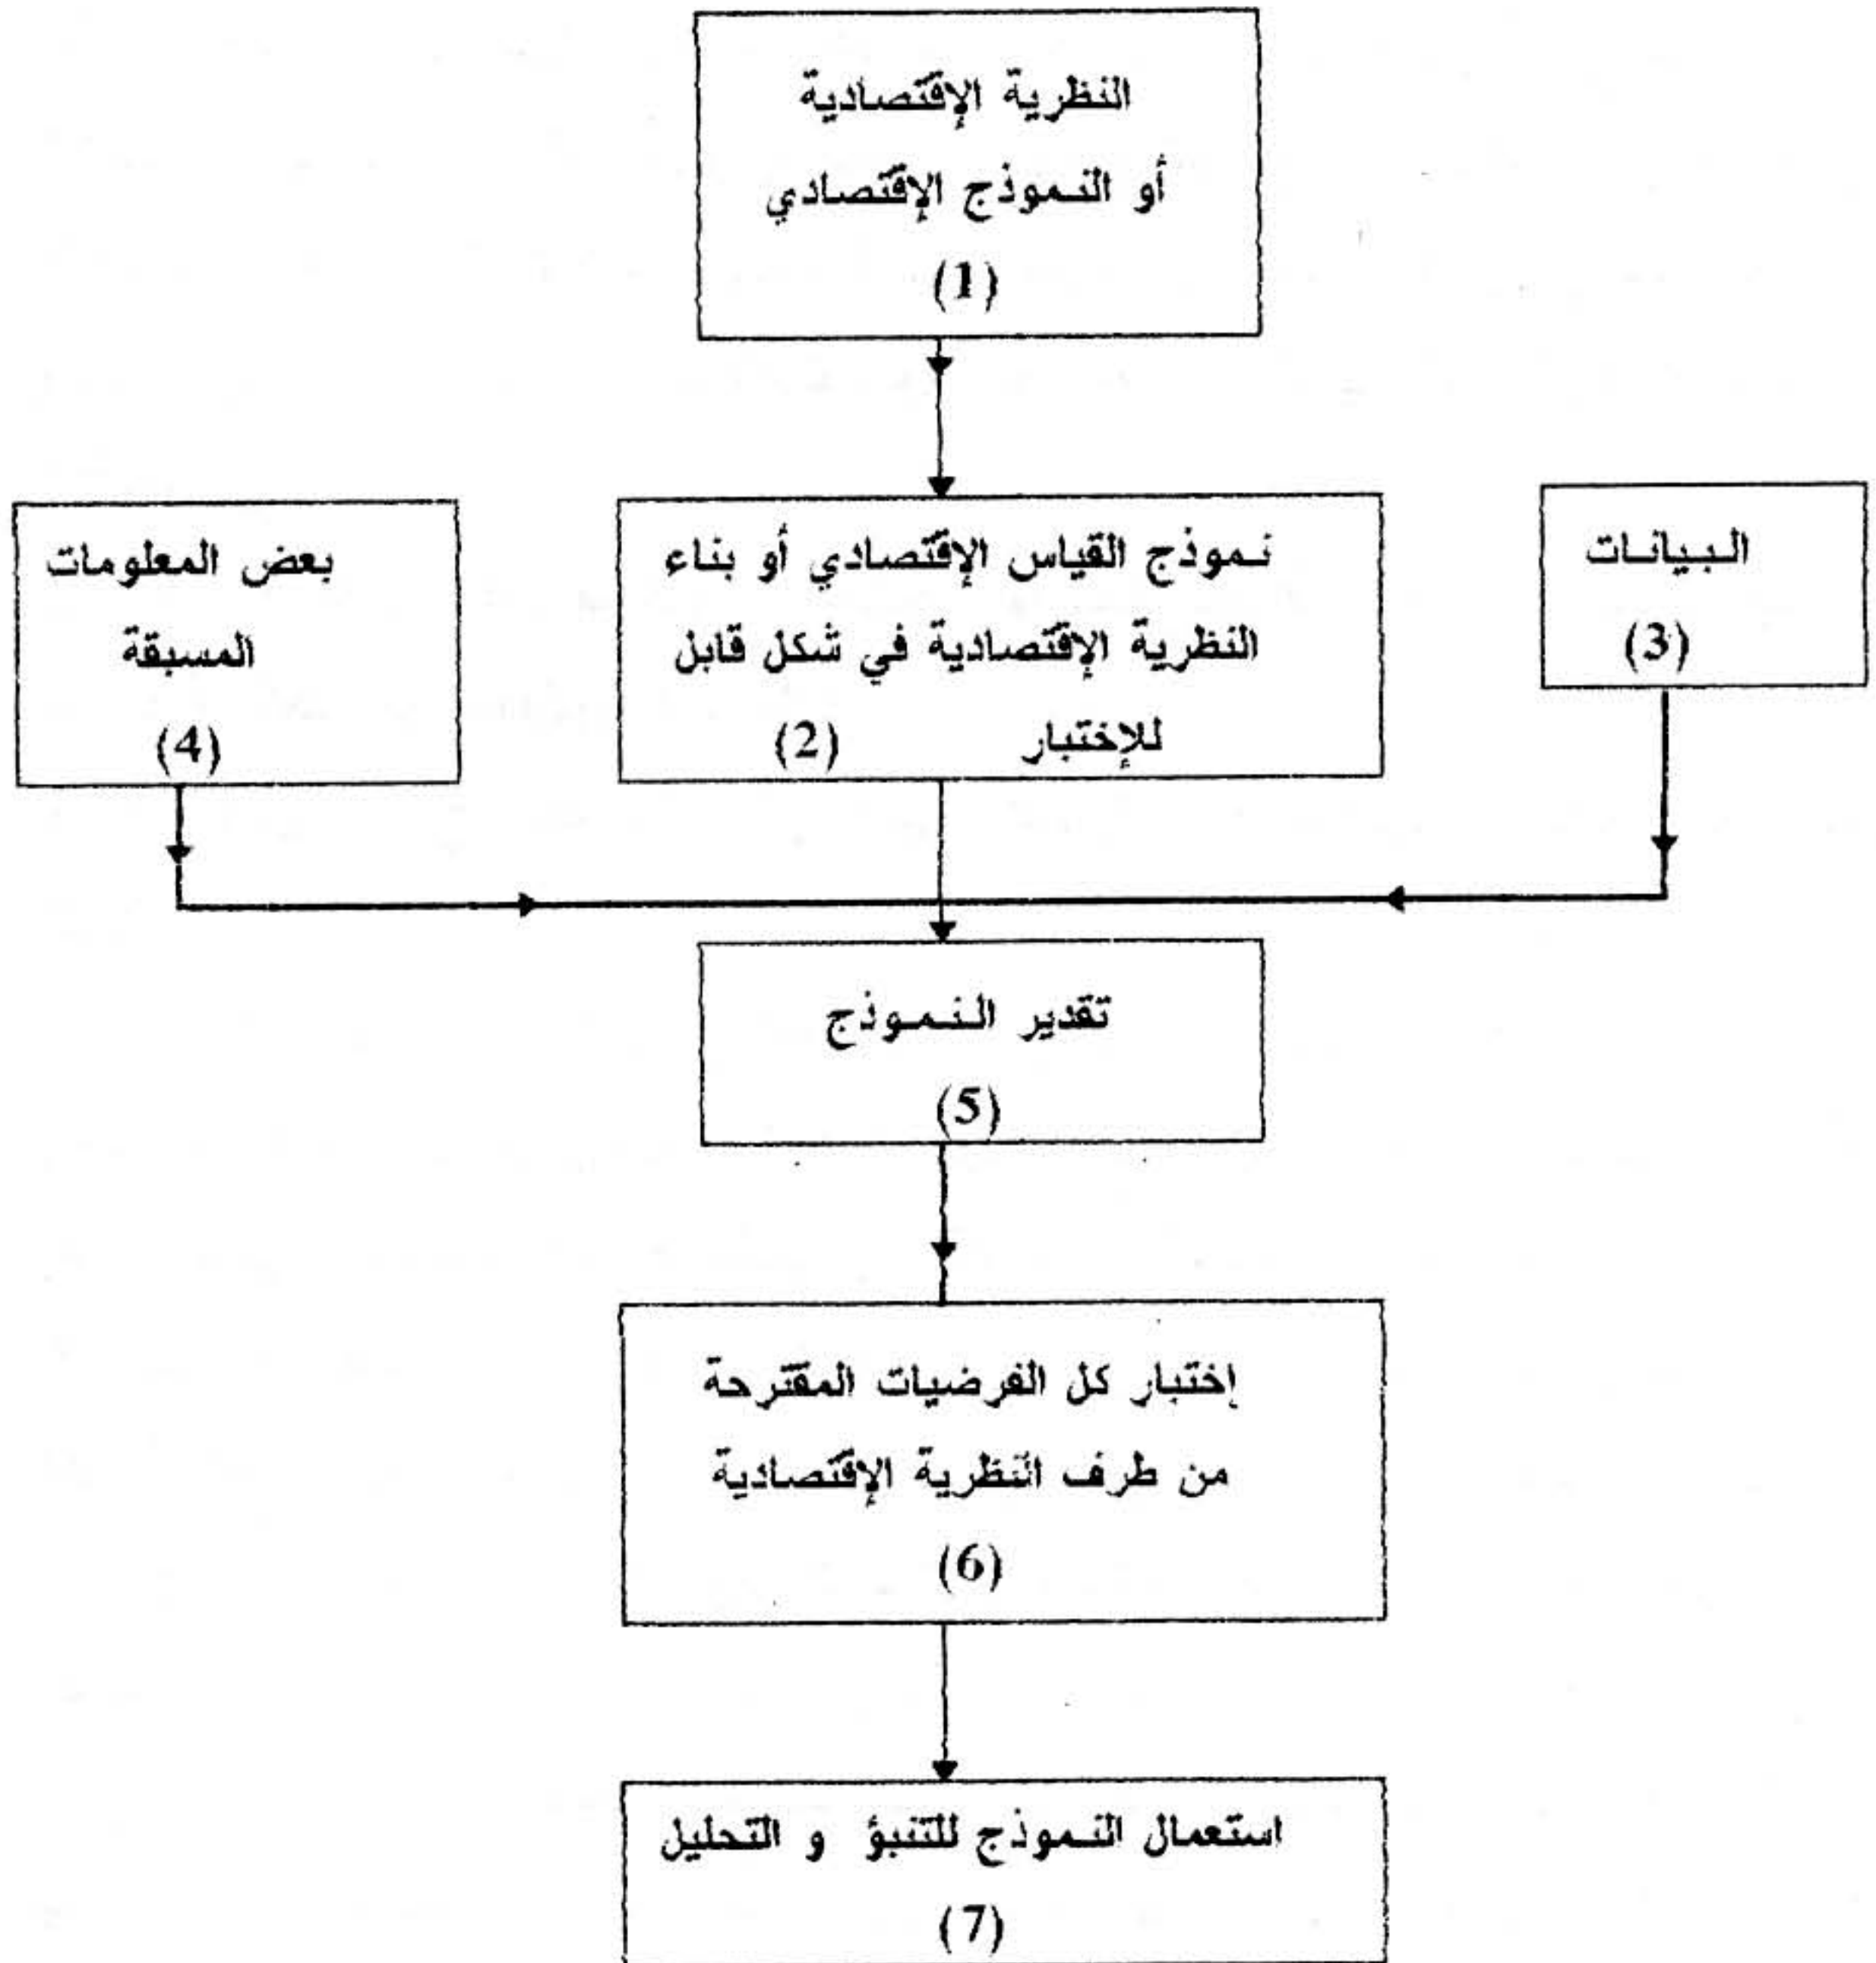
(2) تقدير و اختبار هذه النماذج مستعملين البيانات المتوفرة. و تمثل هذه العملية المرحلة الإحصائية للقياس الإقتصادي.

(3) استعمال النماذج المقدرة لغرض التنبؤ، التحليل الإقتصادي، أو اتخاذ القرارات المناسبة.

لقد أهتم باحثو القياس الإقتصادي في فترة الستينات بالمبادئ الإحصائية. وكانت مجالات التخصيص محدودة جدا. حيث كانت أغلب إهتمامات الباحثين منصبة على التقدير الإحصائي لنماذج القياس الإقتصادي المخصصة بطريقة صحيحة. إذ خصصت هذه الفترة لطرق التقدير البديلة و برامج الكمبيوتر المختلفة. و لم تعطى أهمية لأخطاء التخصيص أو أخطاء في قياس المشاهدات. لكن مع التقدم و التطور السريع لأجهزة و برامج الكمبيوتر المختلفة، أصبحت هذه المشاكل ثانوية، و تغير إهتمام الباحثين إلى مجالات التحليل. و يمكن توضيح ذلك في الشكل (1).

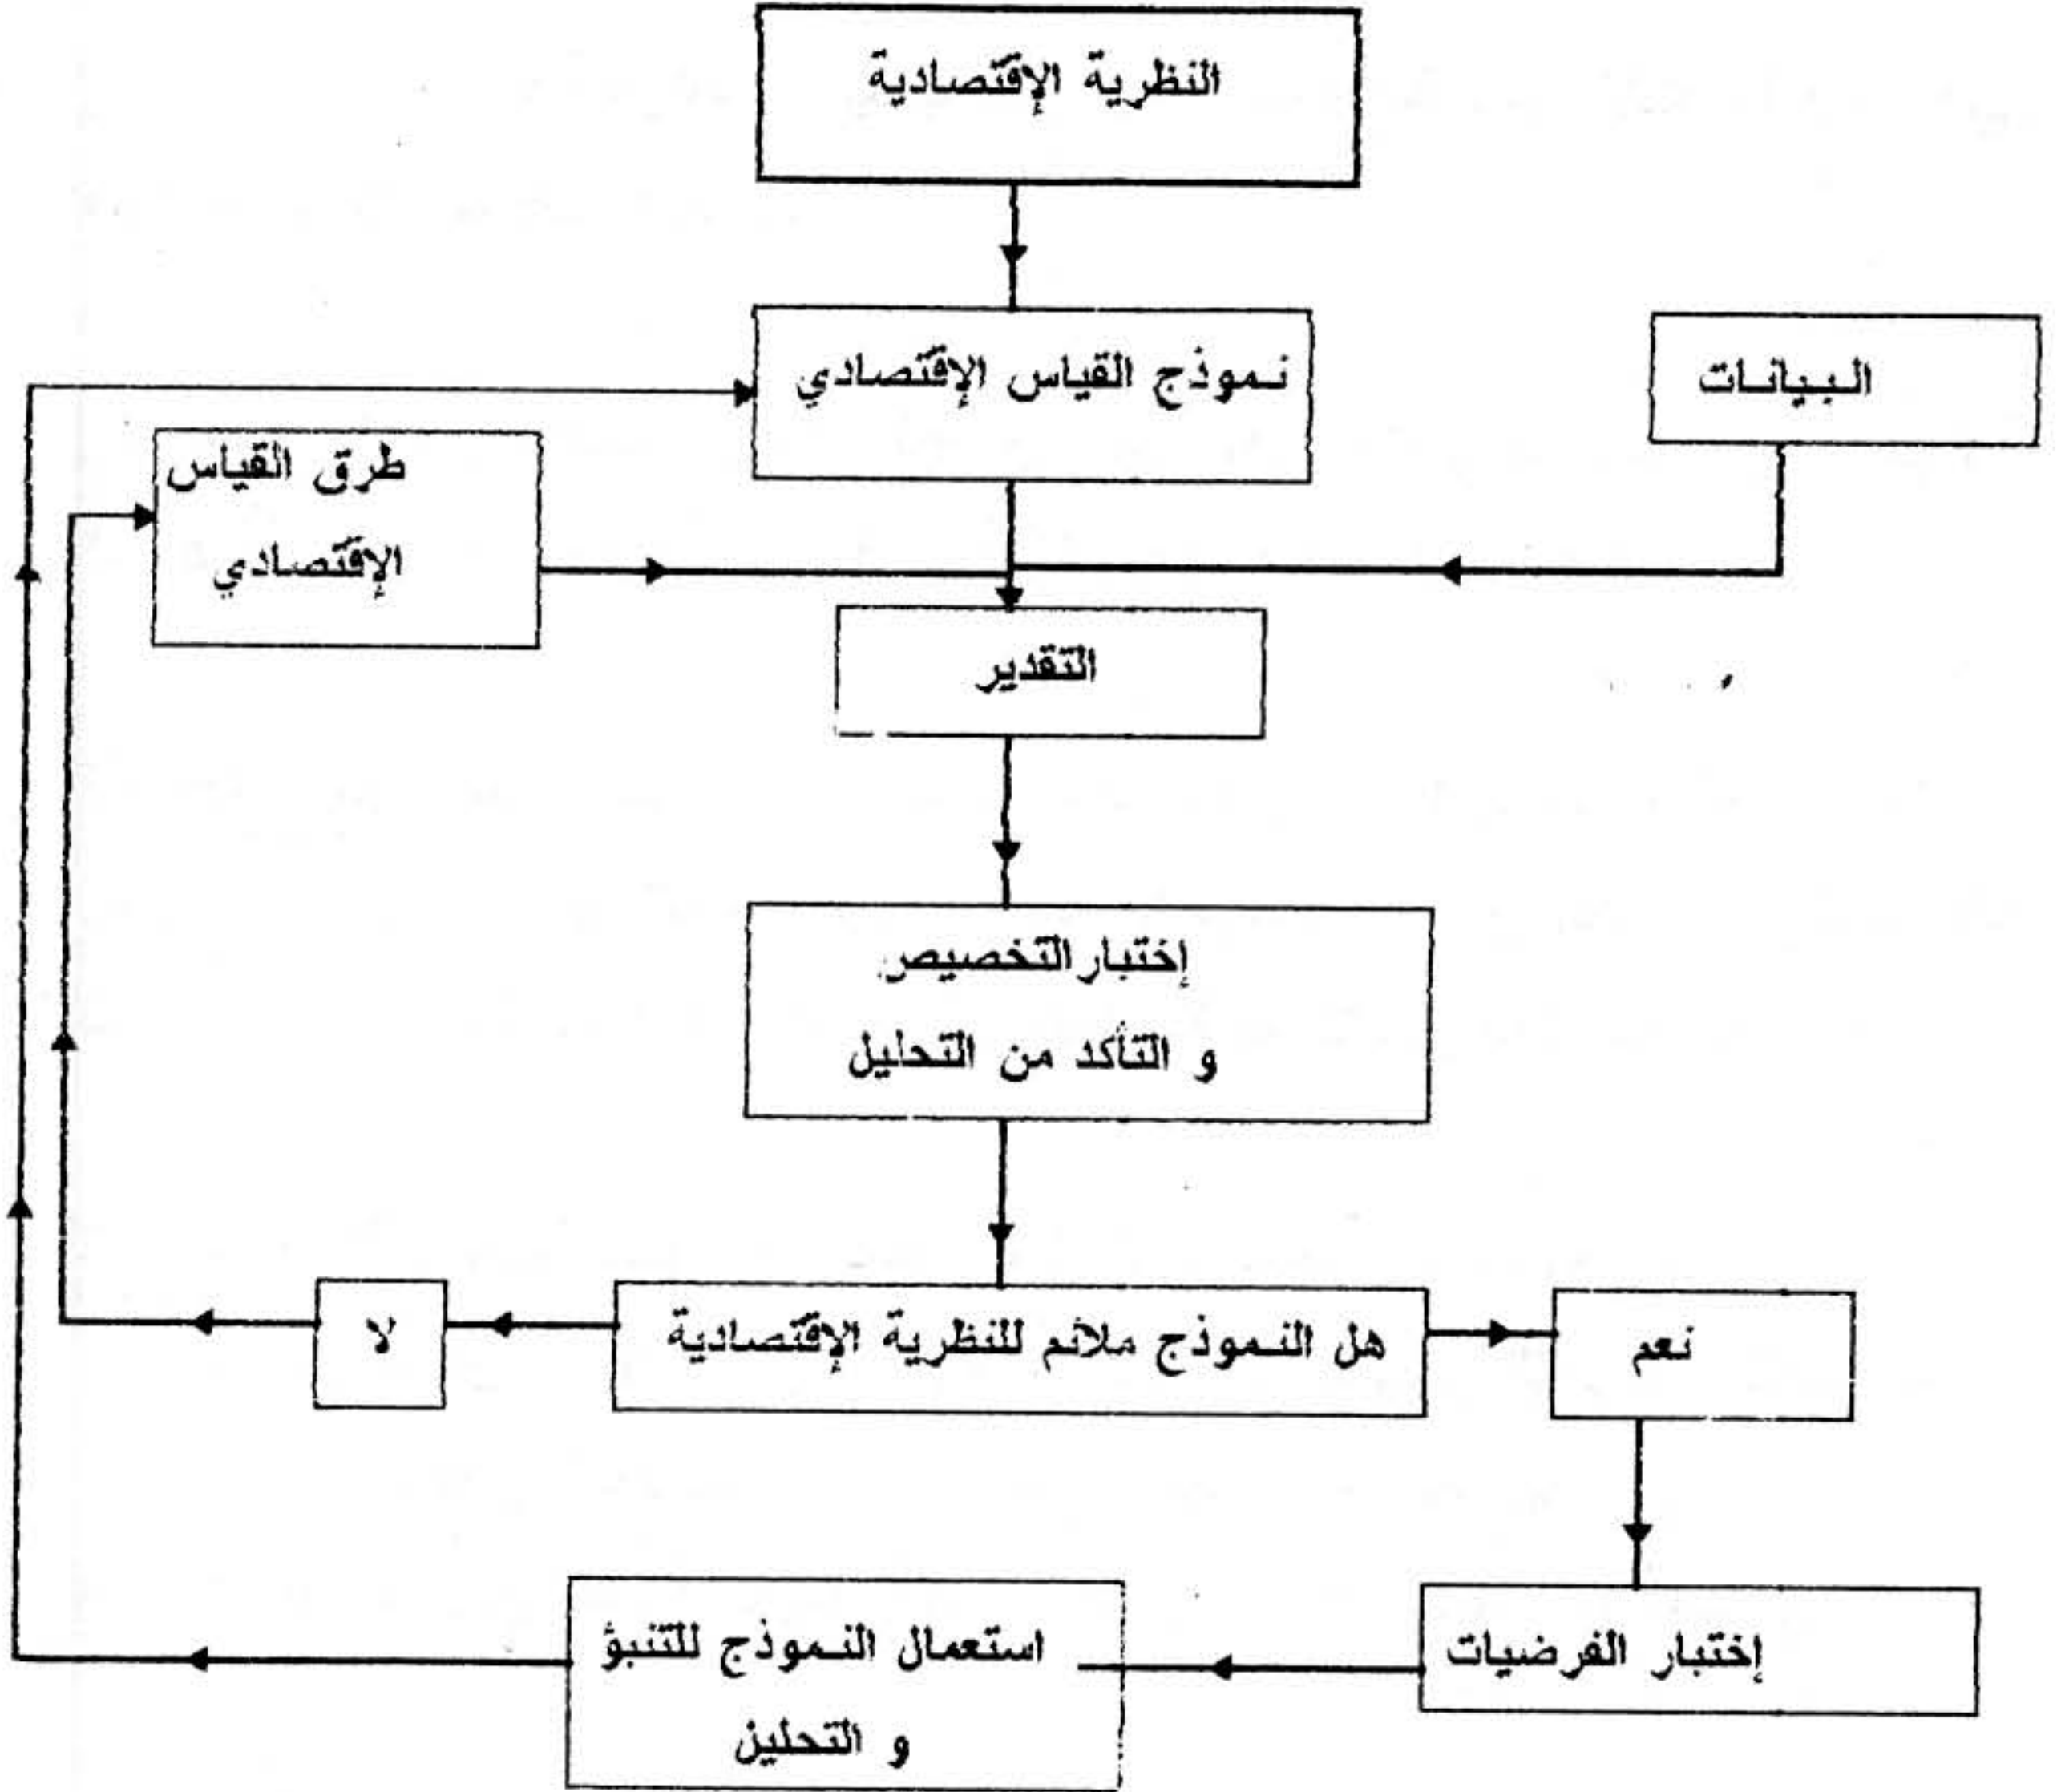
في بداية السبعينات و جهت عدة إنتقادات إلى صياغة الشكل (1)، لأنه يحتوى على طريق واحد للوصول إلى الهدف المنشود. و من هذه الإنتقادات، نلاحظ أنه في الشكل (1) لا يوجد التفاعل المتبادل Feed back ما بين الاختبار

القياسي للنظريات الإقتصادية و الصياغة الرياضية لهذه النظريات. حيث لا يكفي باحثو القياس الإقتصادي بالبيانات المسلمة لهم من طرف جهات أخرى، بل يجب أن يكون هناك تفاعل متبادل من الخطوتين (4) و (5) إلى الخطوة (3). و إذا نظرنا إلى الخطوة (6)، نلاحظ بأن اختبار الفرضيات يشير فقط إلى تلك المقترحة من طرف النموذج الإقتصادي الأصلي في الخطوة (2). ولهذا نرى ضرورة وجود خطوات أخرى في هذا التحليل بالشكل (1).



-الشكل (1)-

وبعد هذه الإنتقادات الموجهة من طرف باحثي القياس الإقتصادي الحديث،  
صحح الشكل (1) على النحو التالي:



-الشكل (2)-



### 1-3-2 مراحل البحث في القياس الإقتصادي

هناك أربعة مراحل رئيسية في أية دراسة للقياس الإقتصادي، وهي موضحة بشكل مختصر فيما يلي:

المرحلة الأولى: تخصيص النموذج: وتشمل إيجاد متغيرات النموذج، الصياغة الرياضية للنموذج، المعرفة المسبقة لإشارة وحجم معالم النموذج.

المرحلة الثانية: تقدير النموذج: وتشمل تجميع البيانات (بيانات مقطعية، سلاسل زمنية، وغيرها)، تمييز الدالة، اختبار درجة الارتباط فيما بين المتغيرات المستقلة لتحديد درجة أو مشكلة التعدد الخطي، واختيار تقنية التقدير المناسبة للنموذج.

المرحلة الثالثة: تقييم النموذج: وتعتمد على ثلاثة مقاييس أساسية وهي:

- (a) المقاييس الإقتصادية المعروفة مسبقاً أو مقاييس النظرية الإقتصادية.
- (b) مقاييس النظرية الإحصائية أو الاختبارات الإحصائية.
- (c) مقاييس نظرية القياس الإقتصادي أو مشاكل القياس الإقتصادي.

المرحلة الرابعة: تقييم قوة التنبؤ للنموذج المقدر عن طريق التأكد من استقرار المقدرات، اختبارات التنبؤ والمحاكاة.

## 4-1 بعض المبادئ الإحصائية

### 1-4-1 خصائص التوقع الرياضي:

(a) ليكن  $X$  متغير عشوائي،  $a$ ،  $b$  ثابتان. إن:

$$E(ax + b) = aE(x) + b$$

$$E[(ax)^2] = a^2 E(x^2) \dots \dots \dots (b)$$

$$E(x^2) \neq [E(x)]^2 \dots \dots \dots \text{ويلاحظ أن:}$$

$$Var(ax + b) = a^2 Var(x) \dots \dots \dots (c)$$

$$Var(x) = E[x - E(x)]^2$$

(d) إذا كانت  $X$  و  $Y$  متغيريتين عشوائيتين فإن:

$$E(x + y) = E(x) + E(y)$$

$$Var(x + y) = Var(x) + Var(y) + 2Cov(x, y)$$

$$Var(x - y) = Var(x) + Var(y) - 2Cov(x, y)$$

(e) لتكن  $X$  مستقلة عن  $Y$  فإن:  $E(xy) = E(x) \cdot E(y)$   
وكذلك:

$$Cov(x, y) = 0$$

$$Var(x \pm y) = Var(x) + Var(y)$$

$$Var(\bar{x}) = Var\left[\frac{1}{n} \sum x_i\right] = \frac{1}{n^2} Var(\sum x_i) \quad (f)$$

$$= \frac{1}{n^2} \sum_i [\text{Var}(x_i)] = \frac{1}{n^2} \sum_i \sigma^2 = \frac{n}{n^2} \sigma^2$$

$$= \frac{\sigma^2}{n}$$

حيث يعرف  $\sigma^2$  على أنه تباين  $X_i$ ، و  $X_i$  مستقلة عن بعضها البعض.

$$E \left[ \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right] = \sigma^2 \dots \dots \dots (g)$$

لأن:  $\sum_{i=1}^n (x_i - \bar{x})^2 = \sum_i [(x_i - m) - (\bar{x} - m)]^2 \dots \dots \dots$

$$= \sum_i \left[ (x_i - m)^2 + (\bar{x} - m)^2 - 2(x_i - m)(\bar{x} - m) \right]$$

$$= \sum_i (x_i - m)^2 + \sum_i (\bar{x} - m)^2 - 2(\bar{x} - m) \sum_i (x_i - m)$$

$$= \sum_i (x_i - m)^2 + n(\bar{x} - m)^2 - 2(\bar{x} - m) \cdot n(\bar{x} - m)$$

$$= \sum_i (x_i - m)^2 - n(\bar{x} - m)^2$$

حيث أن  $m$  هو وسط  $X_i$  ومنه فإن:



$$\begin{aligned}
 E\left[\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2\right] &= E\left[\frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2 - \frac{n}{n-1} (\bar{x} - m)^2\right] \\
 &= \frac{1}{n-1} E\left[\sum_{i=1}^n (x_i - m)^2\right] - \left[\frac{n}{n-1} E(\bar{x} - m)^2\right] \\
 &= \frac{1}{n-1} \sum_i E[(x_i - m)^2] - \frac{n}{n-1} \cdot \frac{\sigma^2}{n} \\
 &= \frac{1}{n-1} (n\sigma^2) - \frac{n}{n-1} \cdot \left(\frac{\sigma^2}{n}\right) = \sigma^2
 \end{aligned}$$

#### 2.4.1 - المتغيرات العشوائية والتوزيعات الاحتمالية:

- نقول عن المتغير  $X$  بأنه متغير عشوائي، إذا كان من أجل كل عدد حقيقي  $a$ ، يوجد احتمال أن تأخذ  $X$  قيمة أقل أو تساوي  $a$  أي  $\text{pr}(X \leq a)$ . وسوف نأخذ القيم  $X, Y, Z$  للتعبير عن القيم الخاصة بالمتغير العشوائي. إن  $\text{pr}(X = x)$  هي احتمال أن يأخذ المتغير العشوائي  $X$  القيمة  $x$ . أما  $\text{pr}(x_1 \leq X \leq x_2)$  فهي احتمال أن يأخذ المتغير العشوائي  $X$  قيمة موجودة ما بين  $x_1$  و  $x_2$ .

- إن القانون الذي يعطي الاحتمالات الخاصة بمختلف القيم التي يأخذها المتغير العشوائي المستمر  $X$  يسمى بالتوزيع الاحتمالي ومنه يمكن تعريفه كمايلي:

$$\text{pr}(x_1 \leq X \leq x_2) = \int_{x_1}^{x_2} f(x) \cdot dx \dots (1.1)$$

### « التوزيع الطبيعي:

ليكن  $X$  متغير عشوائي حقيقي ومستمر. نقول أن  $X$  يتبع القانون الطبيعي إذا كانت دالة كثافته الإحتمالية تكتب على الشكل:

$$\text{pr}(X_i = x) = f(x) = \frac{1}{\sigma_x \sqrt{2\pi}} \exp \left[ -\frac{1}{2\sigma_x^2} (x - m_x)^2 \right]$$

$$-\infty < x < +\infty$$

ويمكن توضيح قانون التوزيع الطبيعي عن طريق وسطه وتباينه. حيث إذا كانت  $X$  موزعة طبيعيا. نكتب:

$$X \sim N(m_x, \sigma_x^2) \dots \dots \dots (1.2)$$

ونقول أن  $X$  موزعة طبيعيا بوسط هو  $m_x$ . وتباين هو  $\sigma_x^2$ . وندرس التوزيع الطبيعي للأسباب التالية:

(a) إن التوزيع الطبيعي متناظر. وهو السبب الذي يساعدنا على معرفة توزيع المعالم التي نريد تقديرها.

(b) إن التوزيع الطبيعي مبين تماما بواسطة وسطه وتباينه. ومنه لانواجه أية صعوبة في إيجاد خصائص العزم الثالث والرابع. وكذا عزوم التوزيعات الإحتمالية من درجة أعلى.

إن النتائج السابقة الذكر والتي تصلح على المتغيرات الطبيعية. تساعدنا على تطوير عدة اختبارات إحصائية مستعملة في القياس الإقتصادي.

### « التوزيع $\chi^2$ :

يستعمل التوزيع  $\chi^2$  لاختبار الفرضيات التي تتعامل مع تباينات المتغيرات العشوائية. حيث إذا كانت  $(X_1, X_2, \dots, X_n)$  سلسلة متغيرات طبيعية

مستقلة. بوسط معدوم  $E(X_i) = 0$ . وتباين الوحدة أي  $\text{Var}(X_i) = 1$

أي :  $X_i \sim IN(0,1) : i=1,2,\dots,n$

ومنه فإن :  $Z = \sum_{i=1}^n X_i^2$  لها توزيع  $\chi^2$  بدرجات حرية هي  $n$ . ونكتبها على

$$Z = \sum_{i=1}^n X_i^2 \sim \chi_n^2 \dots\dots (1.3) \quad \text{الشكل:}$$

- ومنه نقول بأن التوزيع  $\chi^2$  هو توزيع مجموع مربعات  $n$  متغير طبيعي معياري ومستقل. أي إذا كانت  $X_i \sim IN(0, \sigma_x^2)$  فإن :

$$Z = \sum_{i=1}^n \frac{X_i^2}{\sigma_x^2} \sim \chi_n^2 \dots\dots (1.4)$$

- كما يمكن الإشارة إلى أنه إذا كانت  $Z_1 \sim \chi_n^2$  وكذلك  $Z_2 \sim \chi_m^2$  مع  $Z_1$  مستقلة عن  $Z_2$ . فإن :

$$Z_1 + Z_2 \sim \chi_{n+m}^2 \dots\dots\dots (1.5)$$

#### (c) توزيع Student

نفترض إحصائيا في بعض الأحيان بأن تباين المتغير العشوائي يكون معروفا. لكن عمليا هذا غير صحيح (مثلا سنرى فيما بعد عند تحليلنا الإحصائي لمقدرات المعالم). ومنه نصطدم بمشكلة كيفية اختبار الفرضيات لما يكون هذا التباين غير معروف. ولحلها نعرف التوزيع  $t$  :

- إذا كانت  $X \sim N(0,1)$ . وكذلك  $Z \sim \chi_n^2$  مع  $X$  مستقلة عن  $Z$  فإن :



$$Q = \frac{X}{\sqrt{Z/n}} = \frac{N(0,1)}{\sqrt{\chi^2/n}} \sim t_n \dots\dots\dots (1.6)$$

- ومنه نلاحظ أن التوزيع  $t$  هو عبارة عن توزيع المتغير الطبيعي المعياري  $X$  مقسوما على الجذر التربيعي لمعدل المتغير المستقل  $\chi^2$  (أي  $\chi^2$  مقسما على درجات حريته  $n$ ). حيث أن التوزيع  $t$  هو توزيع احتمالي متناظر مثل التوزيع الطبيعي. لكنه محدب أكثر، وطرفيه أطول من التوزيع الطبيعي. وكلما إقتربت درجات الحرية  $n$  من مالاتهاية، يقترب التوزيع  $t$  من التوزيع الطبيعي. كما أن التوزيع  $t$  يصلح للعينات التي تتكون من أو تقل عن 30 مشاهدة. ويطبق هذا التوزيع في اختبار الفرضيات للمعالم الفردية، وسوف يتوضح ذلك عند تطرقنا لإختبار الفرضيات لمعنوية المعالم بالفصل الثاني لاحقا.


#### (d) توزيع Fisher F:

نستخدم هذا التوزيع لما نريد إختبار الفرضيات المجمعة، المحتوية على أكثر من معلمة إنحدار. وعموما، يستعمل هذا التوزيع عند القيام باختبارات محتوية على مساواة بين تباينين على الأقل. ويعرف هذا الأخير كما يلي:

- ليكن  $Z \sim \chi_n^2$  . وكذلك  $X \sim \chi_m^2$  . وإذا كانت  $\chi_n^2$  مستقلة عن  $\chi_m^2$  فإنه يمكن صياغة عبارة للتوزيع  $F$  كما يلي:

$$Q = \frac{X/n}{Z/m} = \frac{X}{Z} \cdot \frac{m}{n} \sim F_{n,m} \dots\dots\dots (1.7)$$

- ويمكن توضيح مختلف التوزيعات المتحدث عنها سابقا في الشكل (3) أدناه.



- الشكل (3) -

### 1-4-3 تعريف المقدّر

إن المقدّر هو تلك القيمة التقديرية التي تأخذها معلمة مجتمع ما ولتكن  $\theta$ . والمسحوبة من عينة عشوائية  $n$  تمثل ذلك المجتمع. ولنعبر متغيراً عشوائياً  $X$ . بحيث يكون توزيعه مرتبطاً بالمعلمة  $\theta$  المطلوب تقديرها. فلتقدير معلمة المجتمع نوفر المعلومة المسبقة *information Prior* التي يمكن أن ترافق المعلومات المعطاة من العينة. إن المعلومة المسبقة تهتم بالمتغير  $X$ . حيث يمكن أن تشمل على فرضيات حول الأشكال التي تأخذها التوزيعات. أو عن قيمة بعض المعالم غير  $\theta$ . أو بعض التخصيصات المتعلقة بـ  $\theta$  نفسها.

إن المعلومات المأخوذة من العينة معطاة بواسطة الملاحظات  $(X_1, X_2, \dots, X_n)$ . وطريقة استعمال هذه المعلومة للحصول على مقدّر

$\theta$  هو ما يعرف بقانون التقدير والمسمى بالمقدر. إن مقدر المعلمة  $\theta$  هو  $\hat{\theta}$ . وما دام  $\hat{\theta}$  مبني على أساس تعويض عينة الملاحظات  $X$  في قانون معين، فإننا نكتب:

$$\hat{\theta} = \hat{\theta}(x_1, x_2, \dots, x_n) \dots \dots \dots (1.8)$$

حيث أن أبسط ميزة لتوزيع المقدر  $\hat{\theta}$  هو وسطه  $E(\hat{\theta})$ . وتباينه  $Var(\hat{\theta})$ .

#### 1-4-4 طرق التقدير

إن أهم الطرق المعروفة في التقدير والقياس الإقتصادي هي ثلاثة وهي:

##### 1- طريقة المربعات الصغرى

استعملت هذه الطريقة لأول مرة من طرف Legendre (1805) وكذلك Gauss (1809) في قياسات علم الفلك. والمشكل المطروح في ذلك الوقت هو تقريب مجموعة الملاحظات  $y_i$  مع بعض الدوال غير المعروفة  $g_i(\theta_1, \theta_2, \dots, \theta_m)$  التي تعتمد على المعام غير المعروفة أيضا  $\theta = (\theta_1, \dots, \theta_m)'$  حيث أن  $i = 1, 2, \dots, n$ ,  $m < n$ . ويعلق Legendre بأنه في حالة ما إذا كانت  $g_i(\theta) = \theta_1$  نقوم بتدئة المقدار  $\sum_{i=1}^n (y_i - \theta_1)^2$  بالنسبة إلى  $\theta_1$ . لنحصل على وسط العينة:

$$\hat{\theta}_1 = \frac{1}{n} \sum_{i=1}^n y_i = \bar{y} \dots \dots \dots (1.9)$$

والذي يعتبر أحسن قيمة تمثل  $(y_1, y_2, \dots, y_n)$ . وبناءا على هذه النتيجة اقترح Legendre تصغير مجموع مربعات الأخطاء وهو ما يسمى بالمربعات الصغرى.

$$l(\theta) = \sum_{i=1}^n (y_i - g_i(\theta))^2 \dots \dots \dots (1.10)$$



مع إفتراض أن الدالة  $g_i(\theta)$  تقبل الاشتقاق وكذلك  $\frac{\partial l(\theta)}{\partial \theta} = 0$  وتعطي المعادلات الطبيعية على الشكل:

$$(-2) \sum_{i=1}^n [y_i - g_i(\theta)] \frac{\partial}{\partial \theta_k} g_i(\theta) = 0 \dots \dots \dots (1.11)$$

$$k = 1, 2, \dots, m$$

$$m < n$$

بينما يقترح Gauss إضافة التوزيع الإحتمالي. حيث إذا كانت العينة العشوائية  $X = (X_1, X_2, \dots, X_n)'$  لها دالة كثافة  $f(x)$  والوسط  $X_n$  هو قيمة تمثيلية من أجل كل  $X_i$ . فإن دالة الكثافة يجب أن تكون طبيعية أي:

$$f(x) = \frac{1}{\sigma_x \sqrt{2\pi}} \cdot \exp \left[ \frac{-1}{2\sigma_x^2} x^2 \right]; x \in R \dots \dots \dots (1.12)$$

ومنه يضع Gauss المشكل على النحو التالي:

$$y_i = g_i(\theta) + u_i; i = 1, 2, 3, \dots, n \dots \dots \dots (1.13)$$

$$u_i \sim IN(0, \sigma_u^2); i = 1, 2, \dots, n \dots \dots \dots (1.14)$$

يشتق بعد ذلك توزيع العينة الممثل لمجموعة الملاحظات  $y = (y_1, y_2, \dots, y_n)$

$$f(y, \theta) = (2\pi\sigma^2)^{-n/2} \cdot \exp \left[ \frac{-1}{2\sigma^2} \cdot \sum_{i=1}^n (y_i - g_i(\theta))^2 \right] \dots \dots \dots (1.15)$$

وتعظيم هذه الدالة  $f(y, \theta)$  بالنسبة لـ  $\theta$ . يعطي نفس المقدر لـ  $\theta$  عندما نقوم

بتصغير مجموع مربعات الأخطاء  $\text{Min} \sum_{i=1}^n [y_i - g_i(\theta)]^2$ . وبتطبيق طريقة

المربعات الصغرى عادة على النماذج الخطية تكون:

$$y_i = \sum_{k=1}^m \theta_k X_{ki} + u_i, i = 1, 2, \dots, n \dots \dots (1.16)$$

وتعوض فرضية التوزيع الطبيعي بالفرضيات التالية:

i)  $E(u_i) = 0$

ii)  $\text{Var}(u_i) = \sigma_u^2 \dots \dots \dots (1.17)$

iii)  $\text{Cov}(u_i, u_j) = E(u_i u_j) = 0 : i \neq j, i, j = 1, 2, \dots, n$

## 2- طريقة العزوم

حسب الطريقة السالفة الذكر. نكتشف بأن المربعات الصغرى ليست قاعدة عامة للتقدير. لأنها تفترض وجود دوال تقريبية  $g_i(\theta)$  تلعب دور الوسيط في النموذج الإحصائي. لكن عمليا. نجد أن المعالم غير المعروفة ليست مرتبطة مع المتوسط. بل تكون لها علاقة مع عزوم من درجة أعلى (مثل التباين). وهذا ما جعل Pearson (1894) يقترح طريقة العزوم كطريقة عامة للتقدير.

لنفرض أن  $X = (X_1, X_2, \dots, X_n)$  هي عينة عشوائية من  $f(x, \theta)$  حيث  $\theta \in \mathbb{R}^k$ . إن العزوم الأولى لـ  $f(x, \theta)$  هي. بالتعريف. دوال للمعالم غير المعروفة. ما دام:

$$\mu'_v(\theta) = \int_{-\infty}^{+\infty} x^v f(x, \theta) dx : v \geq 1 \dots \dots \dots (1.18)$$

ومن أجل تطبيق هذه الطريقة. نمثل المعالم غير المعروفة  $\theta$  على الشكل:

$$\theta_i = g_i(\mu'_1, \mu'_2, \dots, \mu'_k) ; i = 1, 2, \dots, k \dots \dots \dots (1.19)$$

حيث  $g_i$  دوال مستمرة. وتقترح هذه الطريقة لتقدير  $\theta$ . استعمال فكرة التعويض كما يلي:

$$\hat{\theta}_i = g_i(m_1, m_2, \dots, m_k) : i = 1, 2, \dots, k \dots \dots \dots (1.20)$$

حيث أن القيمة  $m_v = \frac{1}{n} \sum_{i=1}^n X_i^v ; v \geq 1$  تمثل عينة العزوم الأولية

و كمقدرات لـ  $\theta$

ومنه إذا كانت  $\mu'_1, \mu'_2, \dots, \mu'_k$  هي دوال لـ  $\theta$  فإن:

$$m_v \xrightarrow{\text{a.s.}} \mu'_v : v \geq 1$$

وبالتالي  $\hat{\theta}_i \xrightarrow{\text{a.s.}} \theta_i$  (حيث أن  $\text{a.s.}$  تعني التقارب المؤكد

والمشروح بالفصل الخامس).



وبالرغم من أن طريقة العزوم تعطي مقدرات متسقة، لكنها غير كفوءة. وهذا ما اكتشفه Fisher في الثلاثينات من هذا القرن .

### 3- طريقة المعقولية العظمى:

نظرا للأشكال المطروح في طريقة العزوم، فإن الباحث Fisher قام بإقتراح وتطوير طريقة المعقولية العظمى عبر مجموعة من البحوث المنشورة خلال فترة الثلاثينات. ثم توسعت هذه المناقشات إلى كتاب وباحثين آخرين أمثال Cramer, Rao و Wald. وتعتبر هذه الأخيرة من أفضل الطرق المستعملة في التقدير. حيث تلعب دورا هاما في اختبار الفرضيات. وتعمت هذه الطريقة على دالة المعقولية العظمى التي تنطلق من فترة سحب كل ملاحظات (ملاحظات) العينة للمتغير العشوائي مرة واحدة دون الاعتماد على قانون لتوزيع الطبيعي. وسوف نتطرق لهذه الطريقة بالتفصيل في تحليلنا ودراستنا القادمة عند مناقشة نظرية العينات الكبيرة والتوزيعات التقريبية بالفصل الخامس لاحقا.

#### 1-4-5 خصائص المقدرات

هناك بعض الخصائص المفضلة لمقدرات والتي سنحتاجها في تحليلنا لاحقا. وقبل ذكر هذه الخصائص نورد المفاهيم التالية:

نتكن لدينا القيسة  $\theta$  والتي هي مقدرة المعلمة الحقيقية  $\theta$  (حيث  $\theta$  هي معلمة المجتمع. بينما  $\theta$  هي مقدرة العينة  $\theta$ ) فإن

i)  $\theta - \theta$  خطأ المعاينة

ii)  $E(\theta - \theta) = 0$  قيمة التحيز

iii)  $E(\theta - \theta)^2 = \sigma^2$  وسط مربع الخطأ

$$\text{iv) } E[\hat{\theta} - E(\hat{\theta})]^2 = \text{التباين}$$

إن خطأ المعاينة هو عبارة عن الفرق بين قيمة المقدرة  $\hat{\theta}$  والقيمة الحقيقية للمعلمة  $\theta$ . ويتغير حجم خطأ المعاينة من عينة لأخرى. أما التحيز فهو الفرق بين وسط توزيع العينة للمقدرة  $E(\hat{\theta})$  والقيمة الحقيقية لتلك المعلمة  $\theta$ . إن هذا الفرق (في التحيز) هو قيمة ثابتة يمكن أن تساوي الصفر أو تختلف عنه.

أما وسط مربع الخطأ فهو مرتبط بتشتت توزيع أية مقدرة  $\hat{\theta}$ . وبالتالي فهو قريب من مفهوم التباين. إن الفرق بين التباين لمقدرة ما  $\hat{\theta}$  ووسط مربع خطئها هو أن التباين يقيس تشتت التوزيع حول وسطه

$$\text{Var}(\hat{\theta}) = E[\hat{\theta} - E(\hat{\theta})]^2$$

بينما يقيس وسط مربع الخطأ التشتت حول

$$\text{M.S.E}(\hat{\theta}) = E(\hat{\theta} - \theta)^2 \quad \text{قيمة المعلمة الحقيقية}$$

إذا تطابق وسط التوزيع مع القيمة الحقيقية للمعلمة. يكون التباين ووسط مربع الخطأ متساويين.

ويمكن أن نبين العلاقة بين التباين ووسط مربع الخطأ كما يلي:

$$\begin{aligned} \text{M.S.E}(\hat{\theta}) &= E(\hat{\theta} - \theta)^2 = E\left[(\hat{\theta} - E(\hat{\theta})) + (E(\hat{\theta}) - \theta)\right]^2 \\ &= E[\hat{\theta} - E(\hat{\theta})]^2 + E[E(\hat{\theta}) - \theta]^2 + 2E[\hat{\theta} - E(\hat{\theta})][E(\hat{\theta}) - \theta] \end{aligned}$$

وما دام الحد الثالث معدوم فإن:

$$\begin{aligned} \text{M.S.E}(\hat{\theta}) &= E[\hat{\theta} - E(\hat{\theta})]^2 + E[E(\hat{\theta}) - \theta]^2 \\ &= \text{Var}(\hat{\theta}) + | \text{قيمة التحيز} |^2 \dots \dots \dots (21.1) \end{aligned}$$

وهذا يعني أنه يستحيل أن تكون قيمة وسط مربع الخطأ أصغر من التباين.

$$M.S.E(\hat{\theta}) - Var(\hat{\theta}) = [E(\hat{\theta}) - \theta]^2 \geq 0$$

$$M.S.E(\hat{\theta}) \geq Var(\hat{\theta}) \dots \dots (1.22)$$

وذلك نوعان من الخصائص المفضلة للمقدرات. النوع الأول يعتني بالعينات الصغيرة الحجم. أما الثاني فيهتم بالعينات الكبيرة.


### 1) خصائص العينات الصغيرة Small Sample Properties

#### (a) عدم التحيز Unbiasedness

يكون مقدار ما  $\hat{\theta}$  غير متحيز إذا كان وسطه  $E(\hat{\theta})$  مساويا لقيمة المعلمة الحقيقية  $\theta$ ، والتي نكون قد قمنا بتقديرها. و نكتب ذلك كما يلي:

$$E(\hat{\theta}) = \theta \dots \dots \dots (1.23)$$

حيث نقول في هذه الحالة بأن  $\hat{\theta}$  هو مقدار  $\theta$  غير المتحيز كما هو مبين بالشكل (4).



الشكل (4)



لكن هذه الخاصية غير كافية أو غير كاملة لأنها لا تأخذ بعين الاعتبار تشتت وتوزيع المقدّر. ففي الحياة العملية يمكن أن نحصل على مقدّر غير متحيز ولكن بتباين كبير. أو على مقدّر متحيز وبتباين صغير عن الأول. في هذه الحالة نختار أيهما أحسن. وهذا يشجعنا للبحث عن خاصية أخرى. قبل ذلك، نقول إذا واجهنا مشكلا من هذا النوع في تحاليلنا الإقتصادية والإحصائية، فإننا نبحث عن الهدف من الدراسة التي نقوم بها. فإذا كان الهدف من دراستنا هو تحليل سياسة إقتصادية أو ظاهرة ما خلال فترة زمنية معينة ومعروفة، نأخذ المقدّر الذي يكون غير متحيز. أما إذا كان هدفنا هو التنبؤ بظاهرة أو حادثة (تصرف) إقتصادية ما، فهنا لا تعنينا قيمة (خاصية) التحيز بقدر ما نهتم بقيمة التشتت الصغيرة. أما إذا كان هدفنا من الدراسة هو التحليل والتنبؤ معا، فنكون مضطرين لتغيير طريقة التقدير أو استعمال طرق إحصائية أخرى من أجل الحصول على مقدّر يحقق أهداف الدراسة.

#### (b) خاصية الكفاءة Efficiency

نظرا للمشكل المذكور بالخاصية الأولى، يساوي بعض الكتاب خاصية الكفاءة مع أصغر وسط مربع الخطأ Minimum Mean Square Error (M.M.S.E)، والبعض الآخر يعرف الكفاءة بالنسبة للعينات الكبيرة فقط. وهناك فريق آخر يعرف ويعتبر أن مقدرا ما، يكون كفوفا إذا وفقط إذا كان غير متحيز وفي نفس الوقت له أصغر تباين، وهذا ما هو معمول به في تقنيات القياس الإقتصادي الحديث. إذن يكون  $\hat{\theta}$  مقدّر  $\theta$  الكفوفا إذا توفر الشرطان التاليان:

$$(i) \hat{\theta} \text{ مقدّر غير متحيز } E(\hat{\theta}) = \theta$$


$$(ii) \hat{\theta} \text{ له أصغر تباين بالمقارنة مع تباين مقدّر آخر } \text{Var}(\hat{\theta}) \leq \text{Var}(\hat{\theta}')$$

حيث أن  $\hat{\theta}'$  هو أي مقدّر غير متحيز آخر لـ  $\theta$ .

ويعرف المقدّر الكفوفا بأنه ذلك المقدّر غير المتحيز و ذو أصغر تباين

Minimum Variance Unbiased Estimator (MVUE)، أو أفضل مقدّر

غير متحيز (Best Unbiased Estimator) (BUE) كما نلاحظ بأن المقدر المتحيز لا يمكن أن يكون كفواً حتى وإن كان له أصغر تباين. ويمكن شرح ذلك من خلال الشكل (٦).



الشكل (5).

من الشكل (5) لدينا توزيعات لثلاثة مقدرات هي  $\hat{\theta}$ ,  $\hat{\hat{\theta}}$ ,  $\hat{\hat{\theta}}$ . ومن هذه المقدرات لدينا  $\hat{\theta}$  لها أصغر تباين، ولكنها غير كفوة بسبب ظاهرة تحيزها. بينما  $\hat{\hat{\theta}}$ ,  $\hat{\hat{\theta}}$  مقدران غير متحيزين، لكن  $\hat{\hat{\theta}}$  لها تباين أكبر من تباين  $\hat{\theta}$ . وبالتالي فإن  $\hat{\hat{\theta}}$  هو مقدر غير كفو. وهذا يترك  $\hat{\theta}$  هو المقدر الكفو شريطة ألا يكون هناك مقدر آخر غير متحيز وبأصغر تباين من تباين  $\hat{\theta}$ .



نلاحظ بأنه عندما تكلمنا عن خاصية عدم التحيز، قمنا بمجرد تطبيق التوقع الرياضي على مقدرة المعلمة، أي وسط توزيع المعاينة  $E(\hat{\theta})$ . بينما بالنسبة لخاصية الكفاءة فإن القضية أصبحت معقدة أكثر، بحيث أننا أصبحنا مجبرين على إجراء مقارنة بين تباينات كل المقدرات غير المتحيزة الموجودة لدينا. لكن، ميدانيا، يمكن أن يكون عدد هذه المقدرات لا نهائي و بالتالي يصعب الحصول على أحسنها. وللخروج من هذه المشكلة جاءت متراجحة كرامر-رو Cramer-Rao Inequality والتي سنتطرق لها بالتفصيل عند دراستنا لنظرية العينات الكبيرة بالفصل الخامس لاحقا.

(c) أفضل مقدر خطي غير متحيز (BLUE) Best Linear Unbiased Estimator  
لاحظنا في الخاصية الثانية، أنه إذا كانت لدينا مجموعة كبيرة من المقدرات غير المتحيزة، فإن مشكلة الحصول على أصغر تباين تعتبر صعبة في بعض الأحيان، وذلك حتى وإن استعنا بمتراجحة كرامر-رو. وللتبسيط أكثر نأخذ مجموعة أصغر من المقدرات غير المتحيزة، وذلك بتقييدنا بمجموعة المقدرات غير المتحيزة وذات الدوال الخطية من نفس عينة الملاحظات (مع الاحتفاظ بخاصية عدم التحيز وأصغر تباين). لنحصل على أفضل مقدر خطي غير متحيز BLUE والذي من شروطه أن تكون:

(i)  $\hat{\theta}$  دالة خطية لعينة الملاحظات

(ii)  $\hat{\theta}$  مقدر  $\theta$  غير المتحيز

(iii)  $\text{Var}(\hat{\theta}) \leq \text{Var}(\hat{\theta}')$  حيث  $\hat{\theta}'$  هو أي مقدر خطي غير متحيز آخر لـ  $\theta$ .

## 2- خصائص العينات الكبيرة Large Sample Properties

### (a) عدم التحيز التقاربي : Asymptotic Unbiasedness

تكون  $\hat{\theta}$  مقدرة  $\theta$  غير المتحيزة تقاربيا إذا كانت

$$\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta \dots\dots (1.24)$$

وهذا يعني أن أي مقدر يكون غير متحيز تقاربيا، إذا كلما إقترب حجم العينة من ما لا نهاية يصبح هذا المقدر غير متحيز. كما أنه إذا كان المقدر غير متحيز أصلا، فإنه يكون، ضمنا، غير متحيز تقاربيا. بينما العكس ليس دائما صحيحا.

### (b) الاتساق Consistency

تكون  $\hat{\theta}$  مقدرة  $\theta$  المتسقة إذا كانت

$$i) \lim_{n \rightarrow \infty} E(\hat{\theta}) = \text{plim}(\hat{\theta}) = \theta \dots\dots (1.25)$$

$$ii) \lim_{n \rightarrow \infty} [\text{Var}(\hat{\theta})] = \text{plim}[\text{Var}(\hat{\theta})] = 0 \dots\dots (1.26)$$

حيث أن:  $\text{plim}(\cdot)$  هي نهاية الاحتمال Probability limit.

ولمعرفة ما إذا كان مقدر ما متسقا أم لا، نلاحظ تحيزه وتباينه عندما يقترب حجم العينة من ما لا نهاية. فإذا كان إرتفاع حجم العينة مرافقا بإنخفاض في قيمة التحيز والتباين معا، ويستمر ذلك الإنخفاض في التحيز والتباين حتى يقترب من الصفر أو يساويه كلما إقترب حجم العينة  $n$  من ما لا نهاية، فإننا نقول عن ذلك المقدر بأنه مقدر متسق.

### (c) الكفاءة التقاربية Asymptotic Efficiency

تكون  $\hat{\theta}$  مقدرة  $\theta$  الكفوة تقاربيا، إذا توفرت الشروط التالية:

(i)  $\hat{\theta}$  مقدرة  $\theta$  المتسقة.

(ii)  $\hat{\theta}$  لها توزيع تقاربي<sup>2</sup> بوسط وتباين مختلفين عن ما لا نهاية.

(iii) لا يوجد أي مقدار متسق آخر له تباين تقاربي أصغر من التباين التقاربي لـ  $\hat{\theta}$ .

حيث نعرف التباين التقاربي لـ  $\hat{\theta}$  كما يلي:

$$\text{Asymptotic Variance } (\hat{\theta}) = \text{Avar}(\hat{\theta}) = \frac{1}{n} \lim_{n \rightarrow \infty} E \left[ \sqrt{n} (\hat{\theta} - \lim_{n \rightarrow \infty} E(\hat{\theta})) \right]^2 \dots (1.27)$$

---

<sup>2</sup> سنطرق بالتفصيل لمفهوم التوزيعات التقاربية بالفصل الخامس



## 5-1 سلسلة تمارين حول الفصل الأول:

- (1) ماذا نعني بالقياس الإقتصادي ؟
- (2) ما الفرق بين النموذج الإقتصادي ونموذج القياس الإقتصادي ؟
- (3) ماهي أهداف ومناهج القياس الإقتصادي ؟
- (4) وضح كيف يمكن لنا إختبار النظرية الإقتصادية ؟
- (5) ما الفرق بين المتغيرات الإقتصادية والمتغيرات العشوائية ؟
- (6) ماذا نقصد بالمقدر ؟ وماهي طرق التقدير الكلاسيكية في القياس الإقتصادي ؟
- (7) ما الفائدة من دراسة خصائص المقدرات ؟ أعطي مثالا عن ذلك.
- (8) ماهي المعايير المستعملة في تقييم نتائج علاقة مقدرة ؟ وأي معيار من هذه الأخيرة يكون أهم ؟
- (9) في دالة الطلب الخطية التالية:  $D = \alpha + \beta p + u$  ( $\beta < 0$ )  
بين بأن الميل  $\beta$  هو مكونة مرونة سعر الطلب. حيث أن  $p$  تمثل السعر، و  $D$  دالة الطلب.
- (10) وضح العلاقة ما بين تباين مقدر ما ووسط مربع خطئه



## الفصل الثاني: نموذج الإنحدار الخطي البسيط

### 1-2 نموذج الإنحدار

يعتبر تحليل الإنحدار الأداة المشتركة والمستعملة في أبحاث القياس الإقتصادي. ويهتم تحليل الإنحدار بتحديد وتقييم العلاقة الموجودة بين متغير معطى (عادة ما يسمى بالمتغير التابع أو المتغير المشروح) ومتغير أو متغيرات أخرى (عادة ما تسمى بالمتغيرات المفسرة أو المتغيرات المستقلة). لقد أستعملت كلمة إنحدار من طرف F.Galton (1822-1911) من بريطانيا عندما كان يدرس العلاقة الموجودة بين قامتي الأبناء وأبائهم.

لنأخذ مثالا عن العلاقة السببية لإنحدار متغير ما في متغير آخر. فإذا عرفنا:  $Y$  هي الإنفاق الإستهلاكي للعائلات،  $X_1$  هي دخل العائلة المتاح،  $X_2$  هي عدد أفراد كل عائلة. نحاول، هنا، تحديد العلاقة الموجودة بين الإنفاق الإستهلاكي للعائلات من جهة، ودخل هذه العائلات من جهة أخرى. وهناك عدة أهداف لدراسة هذه العلاقة منها:

- (1) تحليل الآثار المترتبة عن السياسات المتخذة في تغير وحدات  $X_j$  (أي هنا الدخل)
- (2) التنبؤ بقيمة المتغير التابع  $Y$  (الإنفاق الإستهلاكي) لما تعطى لنا مجموعة قيم  $X_j$ .

- (3) إختبار ما إذا كانت أية متغيرة من المتغيرات  $X_j$  لها أثر إيجابي على المتغير التابع  $Y$ .

من المثال المذكور أعلاه، تخبرنا النظرية الإقتصادية بأن هناك علاقة موجبة بين قيمة الإنفاق الإستهلاكي للعائلات و قيمة الدخل المتاح و المتحصل عليه من طرف هذه العائلات. فلما ترتفع المداخيل، تتبعها زيادة في الإنفاق (أو في الإدخار)، لكن العكس ليس دائما صحيحا. و اعتمادا على الخطوات المذكورة في الفصل الأول، فإن المهمة الأولى لباحث القياس الإقتصادي هي تخصيص نموذج

دالة الإستهلاك. أي تحديد المتغير التابع و المتغيرات المستقلة و عدد المعادلات التي يحتويها النموذج، شكلها الرياضي، عدد المتغيرات المستقلة، إشارة و قيم معالم النموذج وغيرها.

و في مثالنا إذا كان عدد أفراد العائلة  $X_2$  غير معروف فتقترح علينا مبادئ النظرية الاقتصادية بأن المتغير التابع هو الإنفاق الإستهلاكي  $(Y)$ ، أما المتغير المستقل فهو دخل (مداخيل) هذه العائلات  $X$ . و يكون الشكل الرياضي لهذه العلاقة كما يلي:

$$Y = f(X) \dots\dots\dots (2.1)$$

و يمكن أن تكون لدينا توقعات نظرية مسبقة حول إشارة المشتقة الجزئية الأولى لهذه الدالة  $f(X)$ ، أو حول مجال القيم التي تنتمي إليها. فإذا فرضنا أن الدخل هو المحرك الرئيسي لتغير إنفاق العائلة، يكون الشكل الرياضي لدالة الإستهلاك كما يلي:

$$y_i = \alpha + \beta x_i \dots\dots\dots (2.2)$$

و تكون  $\alpha$ ،  $\beta$  هي معالم الدالة و هدفنا هو الحصول على مقدرات عددية لهذه المعالم المذكورة. و ننتظر أن تكون القيمة التقديرية لـ  $\beta$  محصورة ما بين الصفر و الواحد لأنها تمثل الميل الحدي للإستهلاك. إن التخصيص الخطي للعلاقة المذكورة بالمعادلة (2.2)، هو نتيجة للمثال المذكور عن دالة الإستهلاك. لكن عمليا يمكن أن نواجه تخصيصات رياضية لبعض العلاقات الاقتصادية غير الخطية و المعقدة أكثر، حيث يمكن أن تكون هذه التخصيصات في عدة أشكال (ليس بالضرورة أن تكون خطية) مثل:

- i)  $Y = \alpha X^\beta$
- ii)  $Y = \alpha + \beta/X \dots\dots\dots (2.3)$
- iii)  $Y = \alpha + \beta X + \gamma \sqrt{X}$
- iv)  $Y = \alpha + \beta X^\gamma$



إن التخصيص المذكور بالمعادلة الأولى في (3.2) يمكن تحويله إلى شكل خطي عن طريق إدخال اللوغاريتم الطبيعي على هذه الأخيرة لتعطي:

$$\log Y = \log \alpha + \beta \log X = A + \beta \log X$$

حيث تصبح المعادلة المحولة أعلاه خطية في  $\log Y$  و  $\log X$ . أما المعادلة الثانية فهي خطية في  $Y$  و مقلوب  $X$ . كذلك في المعادلة الثالثة يمكن تحويلها إلى الشكل الخطي إذا وضعنا:  $X = Z_1$ ,  $\sqrt{X} = Z_2$  لينتج  $Y = \alpha + \beta Z_1 + \gamma Z_2$ . أما المعادلة الأخيرة، فلا يمكن تحويلها إلى الشكل الخطي و بالتالي لا يمكن أن نطبق عليها الطرق التي سوف نناقشها في هذا الفصل. بل إنها تخضع لطرق أخرى تناقش في تحليل الإنحدار غير الخطي.

إن الخطوة الأولى لتطبيقات القياس الإقتصادي في إيجاد العلاقة ما بين الإتفاق الإستهلاكي للعائلات  $Y$ ، و مداخل هذه العائلات  $X$ ، هي الحصول على  $n$  زوج من الملاحظات الخاصة بهذين المتغيرين. و نكتب عينة الملاحظات  $Y_i$  و  $X_i$ ، حيث  $i = 1, 2, \dots, n$ . ثم يجب إختيار التخصيص المناسب من المعادلات السابقة الذكر (من (2.2) إلى (3.2)). و يكون الإختيار بناءا على تمثيل البيانات الأولية أو تحويلاتها على محورين متعامدين في شكل إنتشاري. فإقتصاديا، تمثل  $\alpha$ ، بالمعادلة (2.2)، حد الكفاف، و  $\beta$  الميل الحدي للإستهلاك. أما هندسيا تمثل  $\alpha$  الحد الثابت الذي يصنع الخط الذي يمر على المحور العمودي  $Y$ . أما  $\beta$  فتمثل ميل هذا الخط.

بعد ذلك، يواجه باحث القياس الإقتصادي مشكلة إستعمال بيانات العينة للحصول على مقدرات عديدة للمعالم غير المعروفة  $\alpha, \beta$ . و إذا كانت العلاقة الموجودة ما بين إنفاق العائلات و إستهلاكها صحيحة، نحصل على عدة نقاط منتشرة، تسمى بالشكل الإنتشاري. إن إيصال هذه النقاط ببعضها البعض يعطينا ذلك الخط المائل. و تكون العلاقة الدالية صحيحة كما هو مبين في المعادلة (2.2). لكن التصرفات الإقتصادية، عمليا، تكون مختلفة و بالتالي غالبا ما يعطينا الشكل الإنتشاري للعلاقة المدروسة نقاطا مختلفة، و ليست كلها على نفس الخط، نظرا

لوجود متغيرات أخرى غير معروفة أو من الصعب الحصول على بيانات تمثلها. هذا الشكل يؤدي بنا إلى توسيع العلاقة السابقة بالمعادلة (2.2) إلى الشكل:

$$Y_i = \alpha + \beta X_i + u_i \dots \dots (2.4)$$

حيث يسمى  $u_i$  الخطأ أو عنصر الإضطراب (Disturbance term) العشوائي، و له توزيع احتمالي معين أي أنه متغير عشوائي. يمثل المقدار  $\alpha + \beta X_i$  بالمعادلة (4.2) العلاقة المحددة لـ  $Y$ . أما  $u_i$  فيعبر عن العلاقة العشوائية. و منه، نطرح السؤال التالي: لماذا نضيف عنصر الخطأ  $u_i$  للعلاقة (2.2)؟ و ما هي مصادر الخطأ في هذه المعادلة؟ نقول توجد عدة مصادر لهذا الخطأ منها:

1- التصرفات العشوائية غير المتوقعة للأفراد. فمثلا في مثالنا عن إنفاق العائلات، تكون بعض التصرفات الخاصة بها غير معروفة. إذ أن العائلة (A) تنفق دخلها بشكل واسع في شهر معين، ثم إن نفس العائلة قد تضطر إلى إدخار جزء هام من دخلها في شهر آخر و بالتالي يقل إنفاقها في ذلك الشهر. كما أنه من غير المنطقي أن تنفق كل العائلات ذات الدخل  $X_i$  نفس القيمة  $\alpha + \beta X_i$ . فحتى العائلات الأخرى ذات نفس الدخل  $X_i$  و من نفس الحجم و التركيب لها إختلافات في عادات و أنواع الإستهلاك.

2- الأثر الذي يحدثه حذف متغيرات مهمة من المعادلة المدروسة، فبالنسبة لبعض العائلات لا يكون الدخل هو المحدد الوحيد للإتفاق الإستهلاكي، بل هناك متغيرات مهمة أخرى مثل حجم العائلة، ذوق أفراد العائلة، توفر السلع في السوق، عادات و تقاليد العائلة وغيرها. فبعض هذه العوامل غير قابلة للقياس مثل العادات والبعض الآخر يمكن ألا تتوفر لدينا بيانات إحصائية عنه. و منه فإن الخطأ العشوائي  $u_i$  يمكن أن يكون عبارة عن مجموع هذه المتغيرات القابلة للقياس (مثل حجم العائلة) و غير القابلة للقياس (العادات و الأنواق) في شكل متغير عشوائي يسمى بعنصر الخطأ أو عنصر الإضطراب العشوائي.



3- أخطاء في قياس المتغير التابع  $Y_i$ . ففي مثالنا يكون من الصعب قياس الإنفاق الاستهلاكي للعائلات بدون أخطاء.

4- قد يكون في بعض الأحيان عدد المتغيرات المستقلة و المتحكممة في المتغير التابع أكبر من عدد الملاحظات المتوفرة لدينا، و بالتالي يكون من غير الممكن الحصول على مقدرات إحصائية مقبولة.

5- خطأ في تخصيص النشئل الدالي للعلاقة المدروسة.

ونشير إلى أنه لايمكننا معرفة قيمة الخطأ العشوائي  $u_i$  مسبقا لكل ملاحظة. و لكننا نضع بعض الافتراضات حول توزيعه الإحتمالي. حيث يمكن للخطأ  $u_i$  أن يأخذ قيما موجبة، سالبة أو معدومة و ذلك لأن أثر المتغيرات المحذوفة أو غير المقاسة يدفع  $Y$  لأن تأخذ قيما أكبر أو أقل من القيمة الحقيقية لها كما سوف نوضح في الشكل (1.2).


فإذا كان عنصر الخطأ  $u_i$  له توزيع مستمر و طبيعي بوسط مساو للصفر و تباين مساو للواحد. فإنه من أجل كل قيمة لـ  $X$  يكون لدينا توزيع طبيعي لـ  $Y$ . ثم إن القيمة الملاحظة لـ  $Y$  يمكن أن تكون أية مشاهدة من هذا التوزيع.

مثال (1.2): إذا كانت العلاقة بين متغيرين  $Y$  و  $X$  على الشكل:

$$Y = 1 + X + u$$

$$u_i \sim N(0, 1)$$

فمن أجل كل قيمة لـ  $X$  يكون لـ  $Y$  توزيع طبيعي مثلما هو مبين في الشكل (1.2).



- الشكل (1.2) - العلاقة العشوائية

حيث أن الخط المرسوم يمثل العلاقة المحددة  $Y = 1 + X$ . إن القيم الحقيقية لـ  $Y$  من أجل كل قيم  $X$  سوف تكون بعض النقاط على الخطوط العمودية الموضحة في الشكل أعلاه. و منه تسمى هذه العلاقة بين  $Y$  و  $X$  بأنها علاقة عشوائية.

## 2-2 طريقة المربعات الصغرى Least Squares Method


إذا كانت لدينا عينة ( $n$ ) من الملاحظات  $Y_i$  و  $X_i$ ، فإننا نكتب المعادلة (4.2) من جديد، ثم نقول أن هدفنا هو الحصول على مقدرات للمعالم غير المعروفة  $\alpha$ ،  $\beta$  لهذه المعادلة. و للقيام بذلك يجب وضع بعض الفرضيات حول النموذج. و يعرف <sup>(1)</sup> J.M. Stigler 1981 طريقة المربعات الصغرى بأنها محرك التحليل الإحصائي الحديث، و ذلك بالرغم من محدوديتها. حوادثها الطارئة و تغيراتها المتعددة، فإنه مازال يعتمد على إمداداتها و توسيعاتها في التحليل الإحصائي و تبقى معروفة و مقيمة من طرف الجميع.

<sup>1</sup> - J.M. Stigler "Gauss and the Invention of Least Squares" The Annals of statistics, Vol 9, N°3, 1981.

أما الكاتب والأستاذ (2) J.J. Johnston فيعرفها على أنها قانون أو طريقة تقدير بعض المعالم غير المعروفة، حيث أن المقدّر هو القيمة العددية لها و الناتجة من تطبيق ذلك القانون أو تلك الطريقة على مجموعة بيانات العينة المعنية بالدراسة.

### 3-2 الفرضيات الكلاسيكية للنموذج أو شروط Gauss-Markov:

إن النموذج المكتوب بالمعادلة (4.2) هو نموذج الإنحدار الخطي البسيط، ويمكن إيجاد مقدرات معالمه  $\alpha$ ،  $\beta$  دون اللجوء إلى هذه الفرضيات التي نحتاجها عند مناقشة خصائص مقدرات المربعات الصغرى فيما بعد حيث تتطلب منا المربعات الصغرى إختيار القيمتين  $\hat{\alpha}$ ،  $\hat{\beta}$  كمقدرتين للمعلمتين  $\alpha$ ،  $\beta$  على الترتيب. وإذا أنطلقنا من عينة الملاحظات  $n$  لكل من  $Y_i$  و  $X_i$  و نرسمها على محورين متعامدين  $Y$  و  $X$ ، حيث يعطي هذا الزوج  $(Y_i, X_i)$  من المتغيرات نقاطا متعددة ومنتشرة في شكل إنتشاري مثلما هو مبين بالشكل (2.2) أدناه



- شكل (2.2) -

2- J.J Johnston "Econometric Methods" International Student Edition Page 16  
USA 1984.



إن أي خط مرسوم ما بين هذه النقاط المنتشرة يمكن أن يمثل تقديرا للعلاقة المفروضة بالمعادلة (4.2) و يكون هذا الخط ممثلا بالعلاقة التقديرية التالية:

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i : i = 1, 2, \dots, n \dots (2.5)$$

حيث تمثل  $\hat{Y}_i$  القيمة التقديرية الموجودة على المحور  $Y$  بالنسبة لأية قيمة تأخذها  $X_i$ . إن الخط الممثل بالمعادلة (5.2) لا يمكن أن يمر على كل النقاط الموجودة بالشكل (2.2)، حيث أن بعض النقاط تظهر تحت الخط و البعض الآخر فوقه.

و ما دامت هذه النقاط تمثل سلسلة الملاحظات  $Y_i$ . فإنها عمليا سوف تنحرف عن سلسلة الملاحظات التقديرية  $\hat{Y}_i$  (بقيم سالبة، موجبة، أو معدومة). وتسمى هذه الانحرافات الموضحة في الشكل (2.2) بالبواقي (بواقي المربعات الصغرى) أو مقدرات الأخطاء و تعرف كما يلي:

$$\hat{U}_i = Y_i - \hat{Y}_i = Y_i - \hat{\alpha} - \hat{\beta} X_i \dots (2.6)$$

ونقول بأن أي خط تقديري سوف ينتج عنه عينة  $n$  من البواقي. إن هدف المربعات الصغرى هو الحصول على أصغر بواقي ممكنة (سالبة أو موجبة). حيث يكون المطلوب منا إختيار المقدرتين  $\hat{\alpha}$ ،  $\hat{\beta}$  بطريقة تجعل مجموع البواقي معدوما

أو أصغر ما يمكن أي:  $\sum_{i=1}^n \hat{U}_i = 0$ . و بإدخال المجموع على (6.2) نجد:

$$\sum \hat{U}_i = \sum (Y_i - \hat{Y}_i) = \sum (Y_i - \hat{\alpha} - \hat{\beta} X_i) = 0$$

$$\sum Y_i = n \hat{\alpha} + \hat{\beta} \sum X_i \dots (2.7) \quad \text{لتعطي:}$$

$$\bar{Y} = \hat{\alpha} + \hat{\beta} \bar{X} \dots (2.8) \quad \text{أي:}$$

إن المعادلة (8.2) تبين لنا بأنه يجب إختيار  $\hat{\alpha}$ ،  $\hat{\beta}$  بطريقة تجعل الخط المقدّر يمر حتما على النقطة  $(\bar{X}, \bar{Y})$  كما هو مبين بالشكل (2.2). لكن، عمليا، يمكن أن نمرر أي خط، مهما كان ميله، على النقطة  $(\bar{X}, \bar{Y})$  لنحصل على الشرط  $\sum \hat{u}_i = 0$ ، و لهذا تشترط طريقة المربعات الصغرى قيودا آخر. لأنه في الشرط



الأول  $\sum \hat{u}_i = 0$ ، يمكن للبواقي السالبة أن تلغي البواقي الموجبة و تكون النتيجة هي الصفر بدون أن يتحقق شرط إختيار المقدرتين  $\hat{\alpha}$ ،  $\hat{\beta}$ . و لذا، فبالإضافة إلى الشرط الأول تقترح طريقة المربعات الصغرى تصغير مجموع مربعات البواقي إلى أدنى قيمة ممكنة لتصبح كل البواقي مربعة و بالتالي موجبة. و بناءا على هذا الشرط يكون المطلوب منا إختيار المقدرتين  $\hat{\alpha}$ ،  $\hat{\beta}$  لكي يكون مجموع البواقي معدوما، و كذلك تصغير مجموع مربعات هذه البواقي. حيث نكتب:

$$Q = \sum_{i=1}^n \hat{u}_i^2 = \sum_{i=1}^n \left( Y_i - \hat{\alpha} - \hat{\beta} X_i \right)^2 \dots\dots (2.9)$$

و لتصغير Q نقوم بإشتقاقها جزئيا بالنسبة للقيمتين  $\hat{\alpha}$ ،  $\hat{\beta}$  على التوالي، ثم نساوي نتيجة ذلك للصفر أي:

$$\text{Min}_{\hat{\alpha}, \hat{\beta}}(Q) = \frac{\partial Q}{\partial \hat{\alpha}} = \frac{\partial Q}{\partial \hat{\beta}} = 0$$

إذن ينتج لدينا من العبارة  $\frac{\partial Q}{\partial \hat{\alpha}} = 0$  المعادلتين (7.2) و (8.2). أما من العبارة  $\frac{\partial Q}{\partial \hat{\beta}} = 0$  نجد:

$$\sum Y_i X_i = \hat{\alpha} \sum X_i + \hat{\beta} \sum X_i^2 \dots\dots\dots (2.10)$$

إن المعادلتين (7.2) و (10.2) تسميان بالمعادلتين الطبيعيين للمربعات الصغرى، و تعويض قيمة  $\hat{\alpha}$  بالمعادلة (8.2) في (10.2) يعطي:

$$\hat{\beta} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(X_i - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2} \dots\dots\dots (2.11)$$

و لنعرف الإنحرافات التالية:

$$y_i = Y_i - \bar{Y}, x_i = X_i - \bar{X}$$

و منه نعيد كتابة (11.2) على الشكل:

$$\hat{\beta} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2} \dots\dots\dots (2.12)$$

و من خصائص المربعات الصغرى للإتحدار الخطي نذكر:

(1) يمر خط الإتحدار على النقطة  $(\bar{X}, \bar{Y})$  حيث  $\sum \hat{u}_i = 0$

(2) تكون التباينات المشتركة للعينة مع كل من قيم الملاحظات  $X_i$  و القيم التقديرية  $\hat{Y}_i$  على التوالي. حيث من المشتقة الجزئية  $\frac{\partial Q}{\partial \hat{\beta}} = 0$

$$\sum X_i \hat{u}_i = 0 \quad \text{نجد أن}$$

$$\text{Cov}(X_i, \hat{u}_i) = \frac{1}{n} \sum (X_i - \bar{X})(\hat{u}_i - \bar{\hat{u}}) = \frac{1}{n} \sum (X_i - \bar{X})\hat{u}_i \quad \text{لأن:}$$

$$\sum \hat{u}_i = 0, \bar{\hat{u}} = 0 \quad \text{و}$$

$$\text{Cov}(X_i, \hat{u}_i) = \frac{1}{n} \sum X_i \hat{u}_i = 0 \quad \text{فإن:}$$

و كذلك نجد أن:

$$\begin{aligned} \text{Cov}(\hat{Y}_i, \hat{u}_i) &= \frac{1}{n} \sum (\hat{Y}_i - \bar{\hat{Y}})(\hat{u}_i - \bar{\hat{u}}) = \frac{1}{n} \sum \hat{Y}_i \hat{u}_i \\ &= \frac{1}{n} \sum (\hat{\alpha} + \hat{\beta} X_i) \hat{u}_i = 0 \end{aligned}$$

(3) يصبح مجموع مربعات البواقي معرفا على الشكل التالي:

$$\begin{aligned} \sum \hat{u}_i^2 &= \sum (Y_i - \hat{\alpha} - \hat{\beta} X_i)^2 \\ &= \sum (Y_i - \bar{Y})^2 + \hat{\beta}^2 \sum (X_i - \bar{X})^2 - 2\hat{\beta} \sum (Y_i - \bar{Y})(X_i - \bar{X}) \\ &= \sum y_i^2 - \hat{\beta} \sum x_i y_i \dots\dots\dots (2.13) \end{aligned}$$

ونستخلص من التحليل السابق بأن المقدرتين  $\hat{\alpha}$ ،  $\hat{\beta}$ ، المعرفتتين

بالمعادلتين (7.2) و (10.2) هما مقدرتي المربعات الصغرى العادية Ordinary Least

Squares (OLS) للمعلمتين  $\alpha$ ،  $\beta$  على التوالي.



و قبل الدخول في مناقشة خصائص مقدرات المربعات الصغرى العادية، يجب الرجوع إلى الفرضيات الأساسية أو شروط Gauss-Markov و نذكر فيما يلي:

- الفرضية الأولى: إن الخطأ  $u_i$  هو متغير عشوائي، يأخذ قيما سالبة، موجبة أو معدومة، لكنها غير مشاهدة، و يخضع لقوانين الاحتمال. يكون وسطه أو توقعه الرياضي مساو للصفر أي  $E(u_i) = 0, i = 1, 2, \dots, n$ .

- الفرضية الثانية: تكون تباينات الأخطاء العشوائية  $u_i$  ثابتة و موجبة بالنسبة لكل ملاحظات العينة. أي تجانس تباينات الأخطاء لكل ملاحظات العينة Homoskedasticity أي أن  $Var(u_i) = E(u_i^2) = \sigma_u^2$

- الفرضية الثالثة: عدم الارتباط الذاتي للأخطاء، أو أن التباينات المشتركة لأخطاء الملاحظات المختلفة تكون معدومة أي أن:

$$Cov(u_i, u_j) = E(u_i u_j) = 0, i \neq j, i, j = 1, 2, \dots, n$$

- الفرضية الرابعة: إنتظام قيم المتغير المستقل  $X_i$  وعدم تغيرها من عينة لأخرى. و أنه مهما اختلف حجم العينة، فإن المقدار  $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  يكون عبارة عن رقم منتهي finite و غير مساو للصفر، أي أن الأخطاء تكون مستقلة عن  $X_i$ .

$$Cov(X_i, u_i) = E(X_i u_i) = X_i E(u_i) = 0, i = 1, 2, \dots, n$$

- الفرضية الخامسة<sup>(3)</sup>: إن الأخطاء  $u_i$  موزعة طبيعيا بالنسبة لكل الملاحظات، وبناءا على الفرضيات الثلاثة الأولى تكون  $u_i$  مستقلة و موزعة طبيعيا بوسط وتباين مذكورين بالفرضيتين الأولى والثانية على الترتيب وتكتب:

<sup>3</sup>- إن الفرضية الخامسة ليست مطلوبة في مناقشتنا لخصائص مقدرات المربعات الصغرى، وإنما نحتاجها عند البحث عن توزيعات هذه المقدرات و تشكيل الاختبارات الإحصائية حول معنوياتها.

$$u_i \sim \text{IN}(0, \sigma_u^2)$$

و باستخدام الفرضية الأولى على المعادلة (4.2) نجد:

$$E(Y_i) = \alpha + \beta X_i \dots \dots (2.14)$$

و تسمى هذه الأخيرة بدالة إحدار المجتمع. أما عند تعويض معلّمتي المجتمع  $\alpha$ ،  $\beta$  بمقدرتيهما فنحصل على معادلة إحدار العينة. و باستعمال الفرضية الثانية على معادلة الإحدار (4.2) و (14.2) يكون تباين المتغير التابع هو نفسه تباين المتغير العشوائي لعنصر الخطأ  $u_i$  أي :

$$\text{Var}(Y_i) = \text{Var}(u_i) = E(u_i^2) = \sigma_u^2$$

و بإضافة الفرضية الخامسة يكون توزيع المتغير التابع  $Y_i$  هو:

$$Y_i \sim \text{IN}(\alpha + \beta X_i, \sigma_u^2)$$

## 4-2 خصائص مقدرات المربعات الصغرى

من المعادلتين (8.2) و (12.2) لدينا مقدرتي المربعات الصغرى

$$\hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X} = \left( \frac{\sum Y_i}{n} - \hat{\beta} \bar{X} \right)$$

و بالتعويض عن  $\hat{\beta} = \frac{\sum X_i Y_i}{\sum X_i^2}$  نجد:

$$\hat{\alpha} = \alpha + \sum \left( \frac{1}{n} - \frac{x_i \bar{X}}{\sum x_i^2} \right) u_i$$

و نعرف المتغير  $W_i$  على الشكل:

$$W_i = \frac{x_i}{\sum x_i^2} \dots \dots (2.15)$$

و الذي يحقق الخصائص:



$$\sum W_i = 0, \sum W_i^2 = \frac{1}{\sum x_i^2}, \sum W_i X_i = \sum W_i x_i = 1 \dots\dots (2.16)$$

و يكون مقدار المربعات الصغرى العادية  $\hat{\alpha}$  هو:

$$\hat{\alpha} = \alpha + \sum \left( \frac{1}{n} - \bar{X}W_i \right) u_i \dots\dots (2.17)$$

أما المقدّر  $\hat{\beta}$  فهو:

$$\hat{\beta} = \sum \left( \frac{x_i}{\sum x_i^2} \right) \cdot Y_i = \sum w_i Y_i \dots\dots (2.18)$$

$$\hat{\beta} = \beta + \sum W_i u_i \dots\dots (2.19)$$

#### 1.4.2 خاصية عدم التحيز

مثلاً وضحنا في الفصل الأول (خصائص المقدرات)، فإن التحيز هو ذلك الفرق بين مقدرة ما و وسط توزيعها. فإذا كان هذا الفرق يختلف عن الصفر، نقول عن ذلك المقدّر بأنه مقدّر متحيز. أما إذا كان هذا الفرق مساو للصفر فإننا نقول عن ذلك المقدّر بأنه مقدّر غير متحيز. و إذا عدنا لمقدرتي المربعات الصغرى العادية  $\hat{\alpha}$ ،  $\hat{\beta}$  المعرفتين بالمعادلتين (17.2) و (19.2) على التوالي، نقول أن تعريف المتغير  $W_i$  بالمعادلة (15.2) يبين لنا بأنه غير عشوائي و مستقل عن الخطأ  $u_i$  و منه يكون:

$$E(W_i u_i) = W_i E(u_i) = 0 \text{ لتصبح:}$$

$$E(\hat{\alpha}) = \alpha + \sum \left( \frac{1}{n} - \bar{X}W_i \right) E(u_i) = \alpha$$

$$E(\hat{\beta}) = \beta + \sum W_i E(u_i) = \beta$$

لنقول أن مقدرتي المربعات الصغرى  $\hat{\alpha}$ ،  $\hat{\beta}$  هما مقدرتي المعلمتين  $\alpha$ ،  $\beta$  على التوالي غير المتحيزتين.

## 2.4.2 خاصية الكفاءة و أصغر تباين:

إن المقدّر غير المتحيز و بأكبر تباين حول القيمة الحقيقية للمعلمة يكون ذا أهمية أقل من ذلك المقدّر غير المتحيز و بأقل تباين. و منه نقول:

$$\text{var}(\hat{\alpha}) = \mathbf{E}[\hat{\alpha} - \mathbf{E}(\hat{\alpha})]^2 = \mathbf{E}[\hat{\alpha} - \alpha]^2$$

$$\text{Var}(\hat{\alpha}) = \sigma_u^2 \sum_{i=1}^n \left[ \frac{1}{n} - \bar{X}W_i \right]^2 = \sigma_u^2 \cdot \frac{\sum X_i^2 \sum W_i^2}{n} \dots (2.20)$$

وكذلك:

$$\text{var}(\hat{\beta}) = \mathbf{E}[\hat{\beta} - \mathbf{E}(\hat{\beta})]^2 = \mathbf{E}[\hat{\beta} - \beta]^2$$

$$\text{Var}(\hat{\beta}) = \mathbf{E}[\sum W_i u_i]^2 = \sigma_u^2 \sum W_i^2 = \frac{\sigma_u^2}{\sum X_i^2} \dots (2.21)$$

أما التباين المشترك فهو:

$$\text{Cov}(\hat{\alpha}, \hat{\beta}) = \mathbf{E}[\hat{\alpha} - \mathbf{E}(\hat{\alpha})][\hat{\beta} - \mathbf{E}(\hat{\beta})] = -\bar{X} \mathbf{E}(\sum W_i u_i)^2$$

$$\text{Cov}(\hat{\alpha}, \hat{\beta}) = -\bar{X} \sigma_u^2 \sum W_i^2 = \frac{-\bar{X} \sigma_u^2}{\sum X_i^2} \dots (2.22)$$

لا يمكننا إصدار حكم حول خاصية أصغر تباين للمقدّرتين  $\hat{\alpha}$  و  $\hat{\beta}$  لأننا نحتاج إلى مقارنتهما بتباينات مقدرات أخرى. و لهذا نبحث عن خاصية أخرى تمكننا من ذلك.

### 3.4.2 أفضل مقدر خطي غير متحيز BLUE

تنطلق هذه الفكرة من نظرية Gauss-Markov و التي تقول:

"من بين المقدرات الخطية و غير المتحيزة، تكون مقدرتي المربعات الصغرى العادية  $\hat{\alpha}, \hat{\beta}$  أفضل مقدرتين خطيتين و غير متحيزتين، حيث أن لها أصغر تباين ممكن مقارنة مع بقية المقدرات الخطية و غير المتحيزة الأخرى". و لإثبات ذلك نعرف أي مقدر خطي آخر  $\beta$ .

$$b = \sum_{i=1}^n C_i Y_i \dots\dots\dots (2.23)$$

$$C_i = W_i + d_i$$

إن  $W_i$  هو عبارة عن قيم ثابتة غير متحركة في كل العينات المتكررة مثلما هو معرف بالمعادلة (15.2)، وله الخصائص المذكورة بالمعادلة (16.2)، أما  $d_i$  فهو عبارة عن ثابت مختار. و لكي يكون  $b$  مقدر  $\beta$  غير المتحيز، يجب أن تتوفر بعض الشروط في  $d_i$ :

$$b = \sum C_i Y_i = \alpha \sum C_i + \beta \sum C_i X_i + \sum C_i u_i$$

$$E(b) = \alpha \sum C_i + \beta \sum C_i X_i$$

و يكون  $E(b) = \beta$  إذا و فقط إذا تحقق الشرطان:

$$i) \sum C_i = 0$$

$$ii) \sum C_i X_i = 1 \dots\dots\dots (2.24)$$

و منه تظهر الشروط الواجب توفرها في  $d_i$  و هي:

$$i) \sum d_i = 0, \sum d_i X_i = \sum d_i X_i = 0 \dots\dots\dots (2.25)$$

ليصبح تعريف المقدر  $b$  بالمعادلة (23.2) على الشكل:

$$b = \beta + \sum C_i u_i \dots\dots\dots (2.26)$$

أما تباينه فهو:



$$\text{Var}(b) = E(b - \beta)^2 = E\left(\sum C_i u_i\right)^2 = \sigma_u^2 \sum C_i^2 \dots\dots\dots(2.27)$$

و بالمقارنة بين (27.2) و (21.2) نجد:

$$\text{Var}(b) = \sigma_u^2 \sum W_i^2 + \sigma_u^2 \sum d_i^2$$

$$\sum W_i d_i = 0 \quad \text{مع}$$

$$\text{Var}(b) = \text{Var}(\hat{\beta}) + \sigma_u^2 \sum_{i=1}^n d_i^2$$

و منه فإن:

$$\text{Var}(b) - \text{Var}(\hat{\beta}) = \sigma_u^2 \sum_{i=1}^n d_i^2 \geq 0$$

من المؤكد أن  $\sum d_i^2$  غير سالبة، و تساوي الصفر فقط إذا كانت كل قيمة

$d_i$  مساوية للصفر. إذن يكون لمقدر المربعات الصغرى العادية  $\hat{\beta}$  أصغر تباين بالمقارنة مع كل تباينات المقدرات الخطية غير المتحيزة الأخرى. وبالتالي يحقق نظرية Gauss- Markov.

أما بالنسبة للمقدرة  $\hat{\alpha}$ ، فلدينا من المعادلة (17.2):

$$\hat{\alpha} = \alpha + \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}W_i\right) u_i$$

و لنعرف أي مقدر خطي و غير متحيز آخر على الشكل:

$$a = \sum_{i=1}^n M_i Y_i$$

$$M_i = m_i + S_i \dots\dots\dots(2.28)$$

و نعيد كتابة المقدرة  $\hat{\alpha}$  على الشكل :

$$\hat{\alpha} = \sum \left[ \frac{1}{n} - \bar{X}W_i \right] Y_i = \sum_{i=1}^n m_i Y_i \dots\dots\dots(2.29)$$

$$m_i = \frac{1}{n} - \bar{X}W_i$$

حيث تصبح  $m_i$  عبارة عن متغير غير عشوائي وله الخصائص التالية:

$$\sum m_i = 1, \sum m_i X_i = 0, \sum m_i^2 = \frac{\text{Var}(\hat{\alpha})}{\sigma_u^2} \dots\dots\dots(2.30)$$

لكي يكون  $a$  مقدار  $\alpha$  غير المتحيز يجب أن تتوفر بعض الشروط في  $S_i$ :

$$a = \sum M_i Y_i = \alpha \sum M_i + \beta \sum M_i X_i + \sum M_i u_i$$

$$E(a) = \alpha \sum M_i + \beta \sum M_i X_i = \alpha$$

إذا وفقط إذا تحقق الشرطان:

$$i) \sum M_i = 1$$

$$ii) \sum M_i X_i = 0 \dots\dots\dots(2.31)$$

و منه بتطبيق الخاصية الموجودة بالمعادلة (31.2) نجد الشروط الواجب

توفرها في  $S_i$  كما يلي:

$$\sum S_i = 0, \sum S_i x_i = \sum S_i X_i = 0 \dots\dots(2.32)$$

$$a = \alpha + \sum M_i u_i \dots\dots\dots(2.33) \quad \text{أما التباين فهو:}$$

$$\text{Var}(a) = E\left[\sum M_i u_i\right]^2 = \sigma_u^2 \sum M_i^2 \dots\dots\dots(2.34)$$

و مقارنة بسيطة بين المعادلتين (34.2) و (20.2) نجد:

$$\text{Var}(a) = \sigma_u^2 \sum m_i^2 + \sigma_u^2 \sum S_i^2$$

$$\text{لأن } \sum S_i m_i = 0 \text{ ومنه نجد:}$$

$$\text{Var}(a) = \text{Var}(\hat{\alpha}) + \sigma_u^2 \sum S_i^2$$

$$\text{Var}(a) - \text{Var}(\hat{\alpha}) = \sigma_u^2 \sum S_i^2 \geq 0$$

و بنفس الطريقة يظهر أن  $\hat{\alpha}$  له خاصية أفضل مقدار خطي غير متحيز و يحقق

شروط نظرية Gauss-Markov.

## 4-4-2 خاصية الاتساق Consistency

إذا واجهنا مشكلة تحيز مقدرة ما، فإننا ننظر إلى الخاصية التقاربية لذلك المقدّر. و يحدث ذلك لما يكون المتغير المستقل  $X$  عبارة عن متغير تابع و متأخر بفترة زمنية ما **Lagged Endogenous Variable**. و نقول عن  $\hat{\beta}$ ، مثلاً، بأنه مقدّر متسق لـ  $\beta$  Consistent estimator، إذا كلما  $n \rightarrow \infty$  فإن توزيع المعاينة لـ  $\hat{\beta}$  يقترب من القيمة الحقيقية  $\beta$ . و نقول أن النهاية الاحتمالية للمقدّر  $\hat{\beta}$  هي  $\beta$  و نكتب:

$$\text{Plim}_{n \rightarrow \infty}(\hat{\beta}) = \beta$$

لكن هذا الشرط غير كاف للحصول على مقدّر متسق، بل يجب أن تكون قيمتي التحيز و التباين تقتربان أو تساويان الصفر كلما اقترب حجم العينة  $n$  من


$$\text{i) } \lim_{n \rightarrow \infty} E(\hat{\beta}) = \text{Plim}_{n \rightarrow \infty}(\hat{\beta}) = \beta$$

مالانهاية أي:

$$\text{ii) } \lim_{n \rightarrow \infty} \text{var}(\hat{\beta}) = \text{Plim}_{n \rightarrow \infty} \text{var}(\hat{\beta}) = 0$$

و بتحقق هذين الشرطين نقول عن المقدّر  $\hat{\beta}$  بأنه مقدّر متسق للمعلمة الحقيقية  $\beta$ . و يمكن توضيح ذلك في الشكلين (3.2) و (4.2).





الشكل (4.2)  $\hat{\beta}$  متحيز و لكنه متنسق      الشكل (3.2)  $\hat{\beta}$  غير متحيز

و بتطبيق الشرطين الخاصين بالإتساق على المقدّر  $\hat{\beta}$  نجد:

$$\lim_{n \rightarrow \infty} E(\hat{\beta}) = \beta + \lim_{n \rightarrow \infty} \sum W_i E(u_i) = \beta$$

$$\lim_{n \rightarrow \infty} \text{var}(\hat{\beta}) = \sigma_u^2 \lim_{n \rightarrow \infty} \left( \frac{1}{\sum X_i^2} \right) = 0$$

حيث كلما  $n \rightarrow \infty$  فإن المقدار  $\sum X_i^2$  يصبح ضخما و منه تكون نهاية المقدار  $\frac{1}{\sum X_i^2}$  معدومة.

لإجراء الاختبارات الإحصائية حول معنوية المعالم نحتاج إلى إيجاد مقدّر تباينات أخطاء العينة، حيث من الفرضية الأساسية الثانية، لدينا تباينات الأخطاء متجانسة  $\sigma_u^2$  لكن هذه القيمة هي معلمة مجتمع و غير معروفة. لدينا بواقي العينة لمقدرات الأخطاء معرفة في المعادلة (6.2) كما يلي:

$$\hat{u}_i = Y_i - \hat{Y}_i = (Y_i - \bar{Y}) - (\hat{Y}_i - \bar{Y}) = y_i - \hat{y}_i$$

ولدينا كذلك:

$$y_i = \beta x_i + u_i - \bar{u}$$

$$\hat{y}_i = \hat{\beta} x_i$$

لتصبح المعادلة (6.2) على الشكل:

$$\hat{u}_i = -(\hat{\beta} - \beta) x_i + (u_i - \bar{u}) \dots \dots (2.35)$$

إن تربيع المعادلة (35.2) و جمعها بالنسبة لكل  $i$  تعطي:

$$\sum \hat{u}_i^2 = (\hat{\beta} - \beta)^2 \sum x_i^2 + \sum (u_i - \bar{u})^2 - 2(\hat{\beta} - \beta) \sum (u_i - \bar{u}) x_i$$

$$E\left(\sum \hat{u}_i^2\right) = E(A) + E(B) - 2E(C)$$

و لنحسب كل حد على انفراد ثم نجمع النتائج:

$$i) E(A) = \text{Var}(\hat{\beta}) \cdot \sum x_i^2 = \sigma_u^2$$

$$ii) E(B) = E\left[\sum (u_i - \bar{u})^2\right] = (n-1)\sigma_u^2$$

$$iii) E(C) = E\left[(\hat{\beta} - \beta) \sum (u_i - \bar{u}) x_i\right] = E\left[\sum w_i u_i \sum x_i u_i\right]$$

$$= E\left[\sum w_i x_i u_i^2 + 2 \sum_{i < j} w_i x_i u_i u_j\right]$$

$$= \sigma_u^2 \cdot \sum w_i x_i = \sigma_u^2$$

و منه نجد:

$$E\left(\sum \hat{u}_i^2\right) = \sigma_u^2 + (n-1)\sigma_u^2 - 2\sigma_u^2 = (n-2)\sigma_u^2$$

$$\frac{E\left(\sum \hat{u}_i^2\right)}{(n-2)} = \sigma_u^2 \dots \dots (2.36)$$

ومنه يكون مقدار تباين الخطأ هو:

$$\hat{\sigma}_u^2 = \frac{\sum \hat{u}_i^2}{n-2} \dots \dots \dots (2.36)$$

وهو مقدار المربعات الصغرى العادية لتباينات الأخطاء  $\sigma_u^2$  غير المتحيز.

## 5-2 الاختبارات الإحصائية حول معنوية المعالم:

بمعرفة توزيع  $\hat{\alpha}$ ،  $\hat{\beta}$ ، يمكن تكوين مجالات ثقة و إجراء اختبار الفرضيات الموضوعة حول معالم الإنحدار  $\alpha$ ،  $\beta$  على التوالي. تقترح مجالات الثقة مجالا للقيم التي يمكن أن تحتوي عليها معالم الإنحدار الحقيقية. مع كل مجال ثقة نضع مستوى إحصائي للمعنوية، فبوجود مستوى المعنوية، نشكل (نكون) هذه المجالات، حيث أن احتمال إحتواء المجال المذكور على معلمة الإنحدار الحقيقية يكون واحدا (1) مطروحا منه مستوى المعنوية أي  $(1-\lambda)$ ، تستعمل مجالات الثقة على الخصوص لإختبار الفرضيات الإحصائية حول معنوية معالم الإنحدار المقدرة. و الاختبار الشائع جدا هو فرضية العدم  $H_0$ ، وتقترح على العموم، فرضية العدم بأنه لا يوجد أثر على النموذج من قبل متغير مستقل ما. و نظرا إلى أن الباحثين يتمنون قبول النموذج، فإن فرضية العدم توضع عادة لإثبات رفضها إذا أمكن ذلك. فمثلا نأخذ دالة الإستهلاك (Y) المشروحة بدلالة الدخل (X) و ننتظر من الدخل والإستهلاك أن يكونا مرتبطين إيجابيا. و بالتالي يكون  $\beta$  موجبا (لأن الميل الحدي للإستهلاك يكون  $0 < \beta < 1$ ). و لإختبار صحة هذه العلاقة نضع:

$$H_0: \beta = 0$$

ونأمل رفض  $H_0$  بإيجاد القيمة التقديرية  $\hat{\beta}$  و التي تكون أكبر من الصفر. حتى نقبل النموذج. إن أحد أهدافنا الأولية في القياس الإقتصادي هو تحليل البيانات، والمقارنة الآنية لعدة نماذج تعتبر، عمليا، صعبة. فتختبر النماذج، عادة، بالتسلسل من أجل الوصول إلى تقييم كل نموذج مثلما وضع تحت الدراسة. هذا



يعني أن كل نموذج يجب أن يخصص في شكل قابل لإختبار الفرضيات ميدانياً، و إن كانت البيانات غير متسقة مع النموذج، يكون هذا الأخير مرفوضاً و نقبل النموذج البديل. و لهذا فإن إختبار الفرضيات يناسب نموذجاً واحداً. وتدل نتائج هذه الإختبارات إما على قبول النموذج أو على رفضه. إن إختيار مستوى المعنوية  $10\%$  يكون عادة عشوائياً، ويعتمد على نوع النهاية التي نريد الوصول إليها من النموذج.

إن مستوى المعنوية الضروري لقبول نموذج ما، يتغير واقعياً فيما بين الباحثين و كذلك بين أنواع النماذج المدروسة، فمثلاً، إن النموذج المقدر بعدد كبير من الملاحظات يمكن أن يسمح لنا برفض فرضيات العدم  $H_0$  لعدة معالم تمثل المتغيرات المستقلة. و لهذا يمكن أن نختار مستوى معنوية منخفضاً حتى نجعل رفض فرضية العدم  $H_0$  أكثر صعوبة. إن الإختبار الإحصائي المناسب لرفض فرضية العدم في مثالنا السابق هو عادة ما يعتمد على التوزيع  $t$ . فالتوزيع  $t$  مناسب لأنه في إختبارنا الإحصائي لمعنوية الميل الحدي للإستهلاك نحتاج إلى إستعمال مقدار تباين الخطأ  $\hat{\sigma}_u^2$  عوضاً عن القيمة الحقيقية للمعلمة  $\sigma_u^2$ . و قبل الوصول إلى ذلك نذكر ببعض المقاييس الإحصائية الضرورية و التي نحتاجها في تحليلنا الإحصائي لمقدرات المربعات الصغرى العادية.

## 2-5-1 إختبار جودة التوفيق بواسطة $F^2$ :

في معادلة خط الإنحدار (5.2) تساعد البواقي على قياس مدى تمثيل المعادلة المفروضة (في النموذج) لمشاهدات العينة. حيث أن القيمة الكبيرة للبواقي تعني بأن التمثيل يكون غير جيد والقيمة الصغيرة لهذه البواقي تعني تمثيلاً جيداً، للنموذج. إن المشكلة في إستعمال البواقي كمقياس لجودة التوفيق هو أن قيمة البواقي تعتمد على المتغير التابع  $Y$ . و لهذا نقوم بتعريف تغير  $Y$  حول وسطها من الشكل (2.2) سابقاً كما يلي:

$$Y_i = \hat{Y}_i + \hat{u}_i$$

$$Y_i - \bar{Y} = \hat{Y}_i - \bar{Y} + \hat{u}_i \dots \dots \dots (2.37)$$

وبتربيع طرفي المعادلة (37.2) أعلاه و جمعها بالنسبة لكل  $i$  نجد:

$$\sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum \hat{u}_i^2 \dots \dots \dots (2.38)$$

إن المقدار  $\sum (Y_i - \bar{Y})^2$  هو مجموع مربعات الانحرافات الكلية في

المتغير  $Y$ ، أي Total Sum of Squares (TSS). أما المقدار  $\sum (\hat{Y}_i - \bar{Y})^2$  فهو

مجموع مربعات الانحرافات المشروحة أو الموضحة Explained Sum of Squares

(ESS). و يبقى الحد الأخير الذي هو مجموع مربعات البواقي Residual Sum of

Squares (RSS). ومنه نعيد صياغة المعادلة (38.2) على الشكل:

$$TSS = ESS + RSS \dots \dots \dots (2.39)$$

و بتقسيم كل الأطراف على الانحرافات الكلية (TSS) نجد:

$$1 = \frac{ESS}{TSS} + \frac{RSS}{TSS}$$

و منه نعرف  $R^2 = r^2$  معامل التحديد كما يلي:

$$R^2 = r^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \dots \dots \dots (2.40)$$

وهو معامل التحديد الذي يقيس و يشرح نسبة الانحرافات الكلية أو

التغيرات التي تحدث في المتغير التابع  $Y$ ، والمشروحة بواسطة تغيرات المتغير

المستقل  $X_1$ .

و ما دام RSS محصور ما بين الصفر (قاتون المربعات الصغرى) و القيمة TSS،

فإن  $R^2$  يكون معرفا وينتمي إلى المجال التالي:  $0 \leq R^2 \leq 1$

4- بالنسبة لنموذج الانحدار الخطي البسيط يكون معامل التحديد هو نفسه مربع معامل الارتباط ما بين متغيرين. أما بالنسبة لنموذج الانحدار المتعدد يصبح هذا التعريف غير صحيح مثلما سنرى في مابعد.



لما يكون  $RSS=0$ ، هذا معناه أن  $R^2$  يأخذ أكبر قيمة له وهي الواحد، أي عندما تقع كل نقاط الملاحظات  $(X_i, Y_i)$  على الخط المقدر  $\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$ ، ويكون التوفيق أحسن ما يمكن. أما لما  $ESS=0$  (أي  $TSS=RSS$ )، فإن  $R^2$  يأخذ أصغر (أسوأ) قيمة له وهي الصفر (أي أنه لا توجد أية علاقة خطية ما بين المتغير المستقل  $X_i$  والمتغير التابع  $Y_i$ ) وهذا معناه أن  $X_i$  لا تشرح  $Y_i$ . ويمكن إيجاد العلاقة بين  $R^2$  و  $\hat{\beta}$  كمايلي:

$$R^2 = \frac{ESS}{TSS} = \frac{\hat{\beta}^2 \sum x_i^2}{\sum y_i^2} = \frac{\hat{\beta} \sum x_i y_i}{\sum y_i^2} \dots\dots (2.41)$$

## 2-5-2 توزيعات المعاينة لمقدرات المربعات الصغرى وأخطائها المعيارية

إن إستعمالنا للفرضية الأساسية الخامسة في إستنباطنا الإحصائي لنموذج المربعات الصغرى يساعدنا على إيجاد توزيعات مقدرات المربعات الصغرى العادية  $\hat{\alpha}$  و  $\hat{\beta}$  والتي تحتوي على تباين الأخطاء  $\sigma_u^2$  و هي القيمة غير المعروفة. و منه نقول بأنه لإشتقاق توزيعات المعاينة للمقدرتين  $\hat{\alpha}$ ،  $\hat{\beta}$ ، نعوض  $\sigma_u^2$  بمقدرها الموجود في المعادلة (37.2) حيث لدينا:

$$\frac{\sum \hat{u}_i^2}{\sigma_u^2} = \frac{(n-2) \hat{\sigma}_u^2}{\sigma_u^2} \sim \chi_{(n-2)}^2 \quad (5) \dots\dots (2.42)$$

و بحصولنا على الوسط و التباين لكل من المقدرتين  $\hat{\alpha}$ ،  $\hat{\beta}$ ، نقول أنه بإستعمال المعادلتين (19.2) و (21.2) يصبح توزيع المقدر  $\hat{\beta}$ :

5- إن  $(n-2)$  هي درجات الحرية حيث تعرف هذه الأخيرة على أنها عبارة عن الفرق ما بين حجم العينة  $(n)$  وعدد لمعالم المطلوب تقديرها في النموذج.



$$\hat{\beta} \sim N\left(\beta, \frac{\sigma_u^2}{\sum x_i^2}\right) \dots\dots (2.43)$$

و كذلك باستعمال المعادلتين (17.2) و (20.2) نجد:

$$\hat{\alpha} \sim N\left(\alpha, \frac{\sigma_u^2}{n} \sum x_i^2 \cdot \sum w_i^2\right) \dots\dots (2.44)$$

و لما نعرف قيمة  $\hat{\sigma}_u^2$  غير المتحيزة، يمكننا تغيير تباينات المجتمع  $\text{var}(\hat{\alpha})$  و  $\text{var}(\hat{\beta})$  إلى تباينات العينة أو مقدرات التباينات. حيث نعرف هذه التباينات على الشكل:

$$\text{var}(\hat{\alpha}) = \frac{\hat{\sigma}_u^2 \sum x_i^2 \cdot \sum w_i^2}{n} = \frac{\hat{\sigma}_u^2 \sum x_i^2}{n \sum x_i^2}$$

$$\text{var}(\hat{\beta}) = \hat{\sigma}_u^2 \sum w_i^2 = \frac{\hat{\sigma}_u^2}{\sum x_i^2}$$

وبناء على هذا التعريف تكون الإنحرافات المعيارية Standard deviations هي الجذور التربيعية لتباينات المقدرات. أما الأخطاء المعيارية Standard errors فهي الجذور التربيعية لمقدرات تباينات المقدرات أو هي مقدرات الإنحرافات المعيارية. أي:

$$S.E(\hat{\beta}) = \sqrt{\text{var}(\hat{\beta})} = \frac{\hat{\sigma}_u}{\sqrt{\sum x_i^2}} \dots\dots (2.45)$$

$$S.E(\hat{\alpha}) = \sqrt{\text{var}(\hat{\alpha})} = \hat{\sigma}_u \cdot \sqrt{\frac{\sum x_i^2}{n \sum x_i^2}} \dots\dots (2.46)$$

ثم نقارن هذه الإنحرافات (الأخطاء المعيارية) مع القيم العددية لمقدرات المربعات الصغرى العادية  $\hat{\beta}, \hat{\alpha}$ . فإذا كانت الأخطاء المعيارية أقل من نصف القيمة

العديدة لمقدرات المعالم  $\hat{\beta}, \hat{\alpha}$  مثلا  $[\text{S.E}(\hat{\alpha}) < \frac{\hat{\alpha}}{2}]$ ، نستنتج بأن تلك المقدرة مقبولة إحصائيا. و هذا معناه رفض الفرضية القائلة بأن  $\alpha = 0$  (أو  $\beta = 0$ )، أما إذا كانت قيمة الأخطاء المعيارية أكبر من نصف قيمة المقدرة، فنقول عن تلك المقدرة بأنها غير جيدة إحصائيا.

### 2-5-3- إختيار التوزيع t

إن تعويض قيمة  $\sigma_u^2$  بمقدورها غير المتحيز ينقلنا من التوزيع الطبيعي إلى التوزيع Student-t لأننا ننتقل من معلمة المجتمع  $\sigma_u^2$  إلى مقدرة العينة  $\hat{\sigma}_u^2$ . وبناءا على تعريف  $\sum \hat{u}_i^2$  في المعادلة (42.2)، تكون هذه الأخيرة موزعة إستقلاليا عن كل من المقدرتين  $\hat{\beta}, \hat{\alpha}$ . حيث لدينا:

$$\hat{\beta} - \beta \sim N\left(0, \frac{\sigma_u^2}{\sum x_i^2}\right) \quad \text{و} \quad \hat{\beta} \sim N\left(\beta, \frac{\sigma_u^2}{\sum x_i^2}\right)$$

إن  $\hat{\beta}$  مستقل عن  $\hat{u}_i$  لأن  $\text{cov}(\hat{\beta}, \hat{u}_i) = 0$ . ثم إن التوزيع الطبيعي المعياري هو:

$$\frac{\hat{\beta} - \beta}{\sigma_u / \sqrt{\sum x_i^2}} \sim N(0, 1)$$

ومع إستقلالية  $\hat{\beta}$  عن  $\chi_{(n-2)}^2$ ، وكذلك  $\hat{\sigma}_u^2$  مستقلة عن  $\sigma_u^2$  لدينا:

$$\frac{\sum \hat{u}_i^2}{\sigma_u^2} = \frac{\text{RSS}}{\sigma_u^2} = \frac{(n-2) \hat{\sigma}_u^2}{\sigma_u^2} \sim \chi_{(n-2)}^2$$

ومن تعريف التوزيع t في الفصل الأول حصلنا على:

$$Q = \frac{n(0,1)}{\sqrt{\chi^2_{(n-2)}/(n-2)}} \sim t_{(n-2)}$$

إذن تصبح:

$$\begin{aligned} \frac{\frac{\hat{\beta} - \beta}{\sigma_u / \sqrt{\sum x_i^2}}}{\sqrt{\frac{RSS}{\sigma_u^2 (n-2)}}} &= \frac{\hat{\beta} - \beta}{\sigma_u \cdot \sqrt{\sum x_i^2}} \cdot \frac{\hat{\sigma}_u}{\sigma_u} \\ &= \frac{\hat{\beta} - \beta}{\hat{\sigma}_u / \sqrt{\sum x_i^2}} = \frac{\hat{\beta} - \beta}{S.E(\hat{\beta})} \sim t_{(n-2)} \dots (2.47) \end{aligned}$$

ونفس الشيء يمكن تطبيقه على المقدرة  $\hat{\alpha}$  لنجد:

$$\frac{\frac{\hat{\alpha} - \alpha}{\hat{\sigma}_u \cdot \sqrt{\frac{\sum X_i^2}{n \sum x_i^2}}}}{S.E(\hat{\alpha})} = \frac{\hat{\alpha} - \alpha}{S.E(\hat{\alpha})} \sim t_{(n-2)} \dots (2.48)$$

#### 4-5-2 مجال الثقة لمعالم الإنحدار

إن رفض فرضية العدم ليس معناه أن المقدرة  $\hat{\alpha}$  (أو  $\hat{\beta}$ ) هي المقدرة الحقيقية لمعلمة المجتمع  $\alpha$  (أو  $\beta$ ). وإنما تعني بأن مقدرتنا حصلنا عليها من عينة مسحوبة من المجتمع الذي تكون معلمته تختلف عن الصفر. و لهذا نستعين بمجالات الثقة لأية معلمة. و لتكوين مجال الثقة من التوزيع  $t$  بالنسبة للمعلمة، مثلا،  $\alpha$  نكتب القانون الخاص بهذه المعلمة:


$$t_{(n-2)} = \frac{\hat{\alpha} - \alpha}{S.E(\hat{\alpha})}$$



وعند مستوى معنوية  $\lambda\%$  يكون مجال الثقة  $(1-\lambda)\%$ . ونجد من جدول التوزيع  $t$  القيمة المحسوبة  $\pm t_{n-2, \frac{\lambda}{2}}$ . وهذا معناه أن احتمال وجود

الإحصاءة  $t$  ما بين  $\pm t_{n-2, \frac{\lambda}{2}}$  يكتب على الشكل:

$$\text{pr} \left[ -t_{n-2, \frac{\lambda}{2}} \leq \frac{\hat{\alpha} - \alpha}{\text{S.E}(\hat{\alpha})} \leq +t_{n-2, \frac{\lambda}{2}} \right] = 1 - \lambda$$



الشكل (5.2) - توزيع المعاينة لـ  $\hat{\beta}$  ثنائي الطرف.

وإذا ضربنا (داخل الاحتمال) كل الأطراف بواسطة  $\text{S.E}(\hat{\alpha})$  وأضفنا  $\alpha$  لأطراف المتراجحة نجد:

$$\text{pr} \left[ \hat{\alpha} - \text{S.E}(\hat{\alpha}) t_{n-2, \frac{\lambda}{2}} \leq \alpha \leq \hat{\alpha} + \text{S.E}(\hat{\alpha}) t_{n-2, \frac{\lambda}{2}} \right] = 1 - \lambda$$

لنجد في الأخير مجال الثقة لـ  $\alpha$  مثلاً:

$$\alpha - S.E(\hat{\alpha}) t_{n-2, \frac{\lambda}{2}} \leq \alpha \leq \hat{\alpha} + S.E(\hat{\alpha}) t_{n-2, \frac{\lambda}{2}}$$

$$C.I(\alpha) = \hat{\alpha} \pm S.E(\hat{\alpha}) t_{n-2, \frac{\lambda}{2}} \dots (2.49)$$

أي أن:

$$\alpha \in \left[ \alpha - S.E(\hat{\alpha}) t_{n-2, \frac{\lambda}{2}}, \alpha + S.E(\hat{\alpha}) t_{n-2, \frac{\lambda}{2}} \right]$$

و كلما كان مجال الثقة ضيقا كلما كان المقدّر أحسن لأن الأخطاء المعيارية (SE(.)) تكون أصغر.

## 5-5-2 اختبار الفرضيات

قد يكون النموذج المبني من طرفنا صحيحا أو غير صحيح و تثبت صحته من خلال إختباره. و يتم ذلك بواسطة فرض معلّمة من معالم النموذج تساوي الصفر أو أي عدد آخر. و تسمى فرضية العدم ( $H_0$ ). وما دامت العلاقة بين  $X$  قائمة على أساس النموذج الخطي. فإن إنعدام هذه العلاقة يعني بأن خط الحدار المجتمع هو عبارة عن خط أفقي أي  $H_0: \beta = 0$ . وبما أن الافتراض  $H_0$  خاضع للاختبار. فإنه لا يكون بالضرورة صحيحا. الأمر الذي يقتضي منا وضع بديل  $H_A$

أي:  $H_A: \beta \neq 0$ . وفي حالة معرفة إشارة  $\beta$  مسبقا من النظرية الاقتصادية. فإن الافتراض البديل يكون  $H_0: \beta > 0$  (أو  $\beta < 0$ ) وإذا طلب منا اختبار الفرضية

فرضية العدم  $H_0: \beta = 0$

ضد فرضية البديل  $H_A: \beta \neq 0$

نكتب:

$$t_{n-2} = \frac{\hat{\beta} - \beta}{S.E(\hat{\beta})} = t_c$$

وهي القيمة المحسوبة

و ما دمنا نختبر فرضية العدم فنكتب  $t_{n-2} = \hat{\beta} / S.E(\hat{\beta})$  ونقول  
نرفض  $H_0$  بمستوى معنوية  $\lambda\%$  إذا كانت:

$$\left| \frac{\hat{\beta}}{S.E(\hat{\beta})} \right| > t_{n-2, \frac{\lambda}{2}}$$

حيث أن  $t_{n-2, \frac{\lambda}{2}}$  مأخوذة من جدول التوزيع  $t$  وتسمى بالقيمة المجدولة. ونقبل  
 $H_0$  بمستوى  $\lambda\%$  إذا كانت:


$$\left| \frac{\hat{\beta}}{S.E(\hat{\beta})} \right| \leq t_{n-2, \frac{\lambda}{2}}$$

أما إذا كانت إشارة  $\beta$  معروفة مسبقا فإننا نكتب:

$$\left| \frac{\hat{\beta}}{S.E(\hat{\beta})} \right| \leq t_{n-2, \lambda} \Rightarrow H_0 \text{ نقبل}$$

ويكون الاختبار أحادي الطرف كما هو مبين بالشكل (6.2).





الشكل (6.2) - توزيع المعاينة لـ  $\hat{\beta}$  أحادي الطرف

توجد عدة تساؤلات لدى باحثي القياس الإقتصادي في الإختبار الإحصائي الأفضل بين معامل التحديد  $R^2$  (أو مربع معامل الارتباط  $r^2$ ) والأخطاء المعيارية للمقدرات  $S.E(.)$ . فأيهما أفضل؟ قيمة عالية لـ  $R^2$  أم قيمة منخفضة للأخطاء المعيارية للمقدرات؟

على العموم، يكون الإختبار سهلا لما نحصل على قيمة عالية لـ  $R^2$  وقيمة منخفضة للأخطاء المعيارية. لكن في الحياة العملية لبحوث القياس الإقتصادي نادرا ما يحدث ذلك. حيث في أغلب الأحيان نحصل على قيمة عالية لـ  $R^2$ ، وفي نفس الوقت على قيم عالية للأخطاء المعيارية لبعض المقدرات. ويرى، في هذا السياق، بعض منظري القياس الإقتصادي أن تعطى أهمية أكثر لقيمة  $R^2$  العالية (رغم ما يشوبه من عيوب<sup>(6)</sup>) ومن ثم يقبلون مقدرات المعالم غير مهتمين بعدم جدية المعنوية الإحصائية لبعض هذه المقدرات.

6- سنرى بالفصل الثالث أن هذا المقياس الإحصائي  $R^2$  له كذلك عيوب.

ويتفق أغلب كتاب القياس الإقتصادي بأنه تعطي أهمية أكثر لـ  $R^2$  لما يكون الهدف من النموذج، قيد الدراسة، هو إستعماله في التنبؤ المستقبلي Forecasting. بينما تعطي أهمية أكبر للأخطاء المعيارية لما يكون هدف الباحث من الدراسة هو التحليل وشرح الظاهرة الإقتصادية. ويفضل الحصول على قيمة عالية لـ  $R^2$  و قيمة منخفضة للأخطاء المعيارية حتى يكون شرحنا أقرب إلى الواقع، حيث لما يحدث تعارض في هذين المقياسين الأساسيين، يجب على الباحث أن يكون حذرا في تفسيره للإتحاد. وقبوله لنتائج التقدير. وفي هذه الحالة تعطي الأولوية للمقاييس الإقتصادية المعروفة (المحددة) مسبقا (مثل حجم وإشارة المقدرات). لأنه بدون قبول هذه المقاييس الأخيرة لا يمكننا الإنتقال إلى المقاييس الإحصائية.

## 6-5-2 إختبار التوزيع F

إن إختبار معنوية (أثر) المتغير المستقل  $X_i$  ( $H_0: \beta = 0$ ) يمكن أن يكون في شكل توزيع F. حيث لدينا التوزيع الطبيعي المعياري:

$$\frac{\hat{\beta} - \beta}{\sigma_u / \sqrt{\sum X_i^2}} \sim N(0, 1)$$

ومن تعريف المتغير  $\chi^2$  في الفصل الأول نجد:

$$\frac{(\hat{\beta} - \beta)^2}{\sigma_u^2 / \sum X_i^2} \sim \chi_{(1)}^2$$

و ما دام  $\left( \text{RSS} / \sigma_u^2 \right) \sim \chi_{n-2}^2$ ، ومستقل توزيعيا عن  $\hat{\beta}$ . فإنه بناءا على

تعريف التوزيع F سابقا نجد:

$$\frac{\chi^2_{(1)}/1}{\chi^2_{n-2}/n-2} = \frac{(\hat{\beta} - \beta)^2 \cdot \sum x_i^2}{\sum \hat{u}_i^2 / (n-2)} = \frac{(\hat{\beta} - \beta)^2 \cdot \sum x_i^2}{\hat{\sigma}_u^2} \sim F_{1, n-2} \dots (2.50)$$

و إذا كانت الفرضية  $H_0: \beta = 0$  صحيحة ينتج أن:

$$F = \frac{\hat{\beta}^2 \sum x_i^2}{\sum \hat{u}_i^2 / (n-2)} = \frac{(n-2) \hat{\beta}^2 \sum x_i^2}{RSS} \sim F_{1, n-2} \dots (2.51)$$

و اعتمادا على المعادلة (40.2) و (41.2) نجد:

$$F = \frac{\hat{\beta}^2 \sum x_i^2}{RSS / (n-2)} = \frac{ESS / 1}{RSS / (n-2)} \sim F_{1, n-2} \dots (2.52)$$

ونقول أننا نرفض  $H_0: \beta = 0$  بمستوى معنوية  $\lambda\%$  إذا كانت:

$$F_{1, n-2} = \frac{\hat{\beta}^2 \sum x_i^2}{RSS / (n-2)} > F_{\lambda, (1, n-2)}$$

حيث أن  $F_{\lambda, (1, n-2)}$  هي القيمة المجدولة. و تؤخذ من جداول توزيع  $F$ . و تقبل

الفرضية  $H_0$  إذا حدث العكس أي:

$$F_{1, n-2} = \frac{\hat{\beta}^2 \sum x_i^2}{RSS / (n-2)} \leq F_{\lambda, (1, n-2)}$$

و بالمقارنة مع التوزيع  $t$  نجد العلاقة التالية:

$$\left( \frac{\hat{\beta} \sqrt{\sum x_i^2}}{\sqrt{RSS / (n-2)}} \right)^2 = \left( \frac{\hat{\beta}}{\hat{\sigma}_u / \sqrt{\sum x_i^2}} \right)^2 \sim [t_{n-2}]^2 \sim F_{1, n-2} \dots (2.53)$$

و هما إختباران متطابقان<sup>(7)</sup>

<sup>7</sup>- تصلح هذه العلاقة (النتيجة) لما نختبر المعالم الفردية لنموذج الإحداد فقط.



و لإيجاد العلاقة الخاصة بالتوزيعين  $F$ ،  $t$  مع معامل التحديد  $R^2$  نعود للمعادلة (40.2) حيث نكتب:

$$ESS = R^2 \cdot TSS = R^2 \cdot \sum y_i^2$$

$$RSS = (1 - R^2) \cdot TSS = (1 - R^2) \cdot \sum y_i^2$$

و لنعوض ذلك بالمعادلة (52.2) فنجد:

$$F = \frac{R^2/1}{(1-R^2)/(n-2)} = \frac{R^2}{(1-R^2)} \cdot (n-2) \sim F_{1, n-2} \dots\dots (2.54)$$

و نظرا للعلاقة الموجودة ما بين التوزيعين  $F$  و  $t$  بالمعادلة (53.2) يمكن كتابة:

$$t = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}} \sim t_{n-2} \dots\dots (2.55)$$

## 6-2 التقدير بطريقة المعقولية العظمى Maximum Likelihood Method

في تطبيقنا لطريقة المربعات الصغرى العادية (OLS)، لم نكن بحاجة إلى استعمال الفرضية الأساسية الخامسة، أو فرضية التوزيع الطبيعي للأخطاء العشوائية  $u_i$ . أما بالنسبة لطريقة المعقولية العظمى فتصبح هذه الأخيرة ضرورية، وبحضور هذه الفرضية يكون المتغير التابع  $Y_i$  موزعا طبيعيا كذلك، حيث من النموذج (4.2) لدينا:

$$Y_i \sim N(\alpha + \beta X_i, \sigma_u^2)$$

حيث نعرف مقدار المعقولية العظمى  $\tilde{\beta}$  للمعلمة  $\beta$  كقيمة تعمم عينة الملاحظات المشاهدة  $(Y_1, Y_2, \dots, Y_n)$ ، و على العموم، إذا كانت  $Y_i$  موزعة طبيعيا، كما هو مبين أعلاه، و كانت كل وحدة من وحدات  $Y_i$  مسحوبة إستقلاليا، فإن مقدار المعقولية العظمى يعظم العبارة التالية:

$$\Pr(Y_1) \cdot \Pr(Y_2) \cdot \dots \cdot \Pr(Y_n) \quad \text{حيث كل } \Pr \text{ تمثل احتمالا متوافقا مع التوزيع}$$

الطبيعي. و قبل تطبيق هذا التعريف مباشرة على نموذج الإنحدار الخطي البسيط هناك ملاحظتان:

(1) إن مقدار المعقولية العظمى المسحوب هو دالة للعينة الخاصة بوحدة  $Y_i$  المختارة. حيث أن سحب عينة مختلفة أخرى سوف يعطينا مقدرا للمعقولية العظمى يختلف عن المقدر الأول.

(2) إن العبارة  $Pr(Y_1). Pr(Y_2).....Pr(Y_n)$  تشير إلى دالة المعقولية Likelihood function. و لا تعتمد دالة المعقولية فقط على قيم العينة، بل على مجموعة المعالم غير المعروفة في النموذج كذلك. و في تعريفنا لدالة المعقولية، ننظر إلى المعالم غير المعروفة على أساس أنها تتغير، بينما تكون قيم  $Y_i$  مثبتة، و تكون هذه النظرة مقبولة، لأن إيجاد مقدار المعقولية العظمى، يحتوي على البحث في مقدرات المعالم البديلة للحصول على تلك المقدرات التي تمثل وتعمم العينة المعطاة في الدراسة. ولهذا السبب، نرى أنه من الضروري أن يكون مفهوم دالة المعقولية مختلفا عن مفهوم التوزيع الإحتمالي المجمع Joint probability Distribution حيث في التوزيع الإحتمالي المجمع تتغير قيم  $Y_i$  بينما تثبت قيم المعالم.

في النموذج الخطي البسيط يكون التوزيع الإحتمالي (أو إحتمال حدوث المشاهدة (i)) للمتغير التابع  $Y_i$  هي كما يلي:

$$Pr(Y_i) = \frac{1}{\sqrt{2\pi\sigma_u^2}} \exp\left[\frac{-1}{2\sigma_u^2} (Y_i - \alpha - \beta X_i)^2\right] \quad (8) \dots (2.56)$$

و تحت فرضية الإستقلال، يكون إحتمال حدوث كل المشاهدات  $Y_i$  مرة واحدة، أو دالة المعقولية (الكثافة الإحتمالية المجمة لكل  $Y_1, Y_2, \dots, Y_n$ ) هو الدالة:

<sup>8</sup> - يمكن أن تسمى المعادلة (2.56) بدالة الكثافة الإحتمالية.



$$L(Y_1, Y_2, \dots, Y_n, \alpha, \beta, \sigma_u^2) = \Pr(Y_1) \cdot \Pr(Y_2) \cdot \dots \cdot \Pr(Y_n) \\ = \prod_{i=1}^n \frac{1}{(2\pi\sigma_u^2)^{1/2}} \exp\left[\frac{-1}{2\sigma_u^2} \sum (Y_i - \alpha - \beta X_i)^2\right] \dots (2.57)$$

و واضح من المعادلة (57.2) أعلاه، أنها دالة للمعالم غير المعروفة  $\alpha, \beta, \sigma_u^2$  وكذلك للقيم  $Y_1, Y_2, \dots, Y_n$  وهي دالة كثافة احتمالية مجمعة، إن طريقة المعقولة العظمى تتطلب منا اختيار قيم المعالم  $\alpha, \beta, \sigma_u^2$  بحيث تعظم المعادلة (57.2) أعلاه.

تسمى هذه الأخيرة بدالة المعقولة، ونرمز لها بالرمز  $L(\alpha, \beta, \sigma_u^2)$ ، أو احتمال مشاهدة كل ملاحظات العينة  $Y_i$  بمعرفة قيم المعالم المذكورة. إن أبسط استعمال لهذه الطريقة (المعقولة العظمى) هو إدخال اللوغاريتم الطبيعي على دالة المعقولة، حيث أنها أصلا دالة نمطية Monotone. كما أن  $\log L(\alpha, \beta, \sigma_u^2)$  سوف تصل إلى أعظم قيمة عند نفس النقطة التي تصلها دالة المعقولة، كما أن إدخال اللوغاريتم سوف يقضي على الحد الأسّي Exponential term. وعند إدخال اللوغاريتم الطبيعي على المعادلة (57.2) نجد:

$$\log L(\alpha, \beta, \sigma_u^2) = \text{Log} L \\ = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma_u^2 - \frac{1}{2\sigma_u^2} \sum (Y_i - \alpha - \beta X_i)^2 \dots (2.58)$$

إن تعظيم المعادلة (58.2) يتطابق مع تصغيرها وذلك لأن كل حدودها في الطرف الأيمن مسبقة بإشارة سالبة. ومنه يكون تعظيم المعادلة المذكورة عن طريق اشتقاقها جزئيا بالنسبة للمعالم غير المعروفة  $(\alpha, \beta, \sigma_u^2)$ ، ثم نساوي مشتقاتها الجزئية للصفر لنجد:



$$\frac{\partial \log L}{\partial \alpha} = \frac{1}{\sigma_u^2} \sum (Y_i - \alpha - \beta X_i) = 0 \dots (2.59)$$

$$\frac{\partial \log L}{\partial \beta} = \frac{1}{\sigma_u^2} \sum [(Y_i - \alpha - \beta X_i) X_i] = 0 \dots (2.60)$$

$$\frac{\partial \log L}{\partial \sigma_u^2} = \frac{-n}{2\sigma_u^2} + \frac{1}{2\sigma_u^4} \sum (Y_i - \alpha - \beta X_i)^2 = 0 \dots (2.61)$$

نحصل على مقدرات المعقولة العظمى  $\tilde{\sigma}_u^2, \tilde{\beta}, \tilde{\alpha}$  للمعالم  $\sigma_u^2, \beta, \alpha$  على التوالي، من المعادلات الثلاث أعلاه على الشكل:

$$\tilde{\alpha} = \bar{Y} - \tilde{\beta} \bar{X} \dots (2.62)$$

$$\tilde{\beta} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} \dots (2.63)$$

$$\tilde{\sigma}_u^2 = \frac{\sum (Y_i - \tilde{\alpha} - \tilde{\beta} X_i)^2}{n} \dots (2.64)$$

كما أنه يمكننا الحصول على المعادلتين التاليتين:

$$\sum Y_i = n\tilde{\alpha} + \tilde{\beta} \sum X_i \dots (2.65)$$

$$\sum X_i Y_i = \tilde{\alpha} \sum X_i + \tilde{\beta} \sum X_i^2 \dots (2.66)$$

إن مقارنة بسيطة ما بين المعادلتين (65.2) و (66.2) والمعادلتين الطبعيتين للمربعات الصغرى (8.2) و (10.2) تجعلنا نستنتج بأن مقدرتي المربعات الصغرى العادية  $(\hat{\beta}, \hat{\alpha})$  متطابقتين مع مقدرتي المعقولة العظمى  $(\tilde{\beta}, \tilde{\alpha})$  على التوالي. أما المعادلة (64.2) فتعطي مقدار المعقولة العظمى لتباينات الأخطاء وهي:

$$\tilde{\sigma}_u^2 = \frac{1}{n} \sum (Y_i - \tilde{\alpha} - \tilde{\beta} X_i)^2 = \frac{RSS}{n} \dots (2.67)$$

لكن قيمة هذه المقدرة  $\tilde{\sigma}_u^2$  تختلف عن قيمة مقدرة المربعات الصغرى العادية  $\hat{\sigma}_u^2$ .

حيث أن الأولى متحيزة (لكنها تقاربيا متسقة)، أما الثانية فهي غير متحيزة حيث أن:

$$E(\tilde{\sigma}_u^2) = E\left(\frac{RSS}{n}\right) = \frac{1}{n} E(RSS)$$

و بإستعمال المعادلة (36.2) نجد:

$$E(\tilde{\sigma}_u^2) = \frac{1}{n} (n-2) \sigma_u^2 = \sigma_u^2 - \frac{2}{n} \sigma_u^2 \dots (2.68)$$

وهي قيمة متحيزة لكن لما  $n \rightarrow \infty$  فتصبح:

$$\lim_{n \rightarrow \infty} E(\tilde{\sigma}_u^2) = \sigma_u^2$$

## 7-2 التنبؤ Prediction

إن أحد الأدوار الرئيسية للقياس الإقتصادي هو التنبؤ بتأثير أحد المتغيرات من طرف المتغيرات الأخرى. فمثلا، نفرض أننا نريد إختبار أثر تخفيض الضريبة على مستوى الإنفاق الإستهلاكي للعائلات، أو أثر زيادة الإنفاق الحكومي على ذلك، فإذا عرفنا بأي مقدار يمكن للضريبة البديلة أن تزيد من الدخل المتاح، نستطيع إستعمال دالة الإستهلاك المقدرة للتنبؤ بأثار الضريبة المخفضة على الإستهلاك. لنأخذ نموذجا البسيط، ولنفرض أننا نعرف قيمة  $X$  في دورة التنبؤ Forecasting period، ونرمز لها بالرمز  $X_f$ . فإذا فرضنا أن البناء الهيكلي للمعادلة لا يتغير في المستقبل، تكون قيمة المتغير التابع  $Y$  في هذه الفترة  $f$  كما يلي:

$$Y_f = \alpha + \beta X_f + u_f \dots (2.69)$$

عندما نستعمل علاقة ما للتنبؤ بالقيمة  $Y_f$ . هناك مصدران لعدم الوضوح

والدقة في تنبؤاتنا وهما:



(1) لا نعرف المعلمتين  $\alpha, \beta$ ، و بالتالي يجب الإعتماد على مقدرتي العينة  $\hat{\alpha}, \hat{\beta}$  لكي تقدر القيمة  $Y_i$ ، إن هذه القيمة هي وسط  $Y$  الموافق لـ  $Y_i$ ، أي:

$$E(Y_i) = \alpha + \beta X_i$$

$$E(Y_i/X_i) = \alpha + \beta X_i \dots\dots (2.70)$$

(2) بالإضافة إلى أن الخطأ  $u_i$  هو متغير عشوائي غير مشاهد. ولهذا، حتى وإن عرفنا قيمتي  $\alpha, \beta$  و بالتالي أستطعنا حساب  $E(Y_i/X_i)$ ، نبقى غير قادرين على التنبؤ بقيمة  $Y_i$  تماما بسبب الخطأ  $u_i$ .

إذن نأخذ، أولا، مقدرا للمقدار  $E(Y_i/X_i)$ ، ونستعين به في التنبؤ بقيمة  $Y_i$  نفسها، ثم نضع مجالا للتنبؤ بـ  $Y_i$ . ومادام:

$$E(Y_i/X_i) = \alpha + \beta X_i$$

فيكون المقدر الطبيعي لها على الشكل:

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i \dots\dots (2.71)$$

ويمكن أن نبين بأن هذا المقدر هو مقدر غير متحيز لـ  $E(Y_i/X_i)$ . وأنه عبر المقدرات الخطية غير المتحيزة الأخرى يعتبر هذا الأخير أحسنها (أي أصغر تباين). ويعرف بإسم أفضل تنبؤ خطي غير متحيز أي Best Linear Unbiased Predictor (BLUP). وتأتي هذه الخاصية من كون  $\hat{\alpha}, \hat{\beta}$  لهما خاصية أفضل مقدر خطي غير متحيز BLUE. وإذا فرضنا أن  $X$  مستقلة، يكون تباين  $\hat{Y}_i$  على الشكل:

$$\text{var}(\hat{Y}_i) = \text{var}(\hat{\alpha} + \hat{\beta} X_i) = \text{var}(\hat{\alpha}) + X_i^2 \text{var}(\hat{\beta}) + 2X_i \text{cov}(\hat{\alpha}, \hat{\beta})$$

وباستعمال المعادلات (20.2)، (21.2) و (22.2) نجد أن:

$$\text{var}(\hat{Y}_i) = \sigma_u^2 \sum w_i^2 \left[ \frac{\sum x_i^2}{n} + (X_i - \bar{X})^2 \right] \dots\dots (2.72)$$

كما يمكن كتابتها على الشكل:



$$\text{var}(\hat{Y}_f) = \sigma_u^2 \left[ \frac{1}{n} + (X_f - \bar{X})^2 \cdot \sum w_i^2 \right] \dots (2.73)$$

و نلاحظ أن تباين مقدار التنبؤ ينخفض كلما:

(1) إنخفضت القيمة  $(X_f - \bar{X})^2$  أي كلما إقتربت  $X_f$  من وسط العينة  $\bar{X}$ .

(2) إزدادت  $n$  أي حجم العينة يزداد.

(3) إزدادت القيمة  $\sum X_i^2$  ، أي كلما إنخفضت القيمة  $\sum w_i^2$ .

لنأخذ الآن هذا المقدّر لـ  $E(Y_f/X_f)$  كقيمة متنبأ بها Predicted

Value بواسطة تقدير وسطها. إن مقدار الخطأ الداخل في هذا التنبؤ معطى بالعلاقة:

$$\hat{u}_f = Y_f - \hat{Y}_f \dots (2.74)$$

و نسميه مقدار خطأ التنبؤ prediction error أو Forecast error ثم نلاحظ أن:

$$E(\hat{u}_f) = E(Y_f - \hat{Y}_f) = 0 \dots (2.75)$$

و يصبح تباين خطأ التنبؤ هو:

$$\text{var}(\hat{u}_f) = \text{var}(Y_f - \hat{Y}_f) = \text{var}(Y_f) + \text{var}(\hat{Y}_f) \dots (2.76)$$

إن قيمة  $Y_f$  تعتمد مباشرة على  $u_f$ ، بينما تعتمد  $\hat{Y}_f$  على

أخطاء العينة  $u_1, u_2, \dots, u_n$  بواسطة المقدرتين  $\hat{\alpha}, \hat{\beta}$  وبالتالي يكون

$$\text{cov}(Y_f, \hat{Y}_f) = 0 \quad (9)$$

ونلاحظ أنه إذا كانت  $X$  مستقلة فإن  $\text{var}(Y_f) = \text{var}(u_f) = \sigma_u^2$

كما وجدنا من قبل. ولدينا  $\text{var}(\hat{Y}_f)$  بالمعادلة (2.73) لنجد:

$$\text{var}(\hat{u}_f) = \sigma_u^2 \left[ 1 + \frac{1}{n} + (X_f - \bar{X})^2 \cdot \sum w_i^2 \right]$$

$$\text{cov}(Y_f, \hat{Y}_f) = E[(Y_f - E(Y_f))(\hat{Y}_f - E(\hat{Y}_f))]$$

$$= E[u_f((\hat{\alpha} - \alpha) - (\hat{\beta} - \beta)X_f)]$$

$$= E[u_f(\sum (\frac{1}{n} - \bar{X}X_i)u_i)] - E[X_f u_f - \sum w_i u_i] = 0$$

و لنعرف  $\text{var}(\hat{u}_r) = \sigma_{uf}^2$  لنجد أن:

$$\sigma_{uf}^2 = \sigma_u^2 \left[ 1 + \frac{1}{n} + (X_r - \bar{X})^2 \cdot \sum w_i^2 \right] \dots (2.77)$$

و منه فإن المقدّر غير المتحيّز لتباين خطأ التنبؤ  $\text{var}(\hat{u}_r)$  هو:

$$\hat{\sigma}_{uf}^2 = \hat{\sigma}_u^2 \left[ 1 + \frac{1}{n} + (X_r - \bar{X})^2 \cdot \sum w_i^2 \right] \dots (2.78)$$

و نلاحظ أنه كلما كبر حجم العينة فإن  $\hat{\sigma}_{uf}^2$  تقترب من  $\hat{\sigma}_u^2$  أي

$$\lim_{n \rightarrow \infty} (\hat{\sigma}_{uf}^2) = \hat{\sigma}_u^2$$

و لهذا فعندما يكون حجم العينة كبيرا يمكن استعمال  $\hat{\sigma}_u$  كتقريب لـ  $\hat{\sigma}_{uf}$ .

نأمل الآن في إيجاد مقياس لتحديد دقة هذا التنبؤ لـ  $Y_r$ . وللقيام بذلك نفرض توزيعا احتماليا معينا للإضطرابات العشوائية، وهو التوزيع الطبيعي. ثم مادام  $u_r$  موزع طبيعيا وكذلك  $Y_r$ ، كما أن أخطاء العينة  $u_1, u_2, \dots, u_n$  موزعة طبيعيا، وكذلك  $\hat{\alpha}, \hat{\beta}$  فإن  $\hat{Y}_r$  تكون موزعة طبيعيا أيضا. ولهذا فإن خطأ التنبؤ،  $\hat{u}_r = Y_r - \hat{Y}_r$  يكون متغيرا عشوائيا موزعا توزيعا طبيعيا بوسط مساو للصفر وتباين هو  $\sigma_{uf}^2$ . أما مقدّر هذا التباين فهو  $\hat{\sigma}_{uf}^2$ .  
و منه فإن:

$$Z = \frac{\hat{u}_r}{\sigma_{uf}} \sim N(0, 1)$$

كما أن  $\sigma_{uf}^2$  تعتمد على القيمة غير المعروفة  $\sigma_u^2$  كما في المعادلة (77.2). فعليا نعوض بمقدرها  $\hat{\sigma}_{uf}^2$  لتعطي المتغير العشوائي للتوزيع t كمايلي:

$$\frac{\hat{u}_r}{\hat{\sigma}_{uf}} = \frac{Y_r - \hat{Y}_r}{\hat{\sigma}_{uf}} \sim t_{n-2}$$

إذا كانت  $t$  هي القيمة الحرجة (من الجدول) لتوزيع  $t$  بحيث تحقق:

$$\text{pr} \left[ t_{n-2, \frac{\lambda}{2}} \leq \frac{Y_f - \hat{Y}_f}{\hat{\sigma}_{uf}} \leq t_{n-2, \frac{\lambda}{2}} \right] = 1 - \lambda$$

فإن مجال الثقة للتنبؤ يكون:

$$\hat{Y}_f - \hat{\sigma}_{uf} \cdot t_{n-2, \frac{\lambda}{2}} \leq Y_f \leq \hat{Y}_f + \hat{\sigma}_{uf} \cdot t_{n-2, \frac{\lambda}{2}}$$

$$Y_f \in \left[ \hat{Y}_f - \hat{\sigma}_{uf} \cdot t_{n-2, \frac{\lambda}{2}}, \hat{Y}_f + \hat{\sigma}_{uf} \cdot t_{n-2, \frac{\lambda}{2}} \right]$$

$$C.I(Y_f) = \hat{Y}_f \pm \hat{\sigma}_{uf} \cdot t_{n-2, \frac{\lambda}{2}} \dots\dots\dots (2.79)$$

## 8-2 أخطاء في المتغيرات:

تكون المتغيرات الإقتصادية في الواقع العملي مقاسة بطرق ليست دائما صحيحة بالتمام. فهناك نسبة من الخطأ موجودة أثناء قياس المتغيرات أو جمع البيانات إلى آخره. فمثلا إذا قمنا بإجراء إستقراء أو إستجواب بعض الأفراد حول ظاهرة إقتصادية ما، أو تصرف إجتماعي معين، لا ننتظر أن تكون كل إجاباتهم صحيحة و هذا لإختلاف طبيعة الأفراد. وهناك نوعان من الأخطاء في قياس المتغيرات:



(1) أخطاء القياس المتعلقة بالمتغير المستقل:

لنبقى دائما مع نموذجنا الخطي البسيط، فإذا أحتوت الملاحظات  $X_i$  على

أخطاء في شكل  $X_i^*$ ، وإذا كانت هذه الأخطاء عشوائية تصبح  $X_i^*$  كمايلي:

$$X_i^* = X_i + W_i \Rightarrow X_i = X_i^* - W_i \dots \dots \dots (2.80)$$

حيث أن  $W_i$  تمثل الخطأ الناتج عن قياس القيمة  $X_i$ . فإذا كانت  $W_i$

تتطبق عليها الفرضيات الأساسية للنموذج (4.2)، ومستقلة عن  $u_i$  و  $X_i$ ، يمكن

كتابة النموذج البسيط على الشكل:

$$Y_i = \alpha + \beta \left( X_i^* - W_i \right) + u_i$$

و تصبح المعادلة المطلوب تقديرها هي:

$$Y_i = \alpha + \beta X_i^* + u_i^* \dots \dots \dots (2.81)$$

حيث:

$$u_i^* = u_i - \beta W_i$$

ومنه نلاحظ أن الخطأ الجديد  $u_i^*$  في هذه المعادلة ليس مستقلا عن المتغير

المستقل  $X_i^*$  أي:

$$E \left( X_i^* u_i^* \right) = E \left( X_i + W_i \right) \left( u_i - \beta W_i \right)$$

و إذا فرضنا أن  $E \left( W_i^2 \right) = \sigma_w^2$  فإن:

$$E \left( X_i^* u_i^* \right) = -\beta \sigma_w^2 \dots \dots \dots (2.82)$$

و هي قيمة تختلف عن الصفر. وبالتالي فإن المربعات الصغرى للمقدر  $\hat{\beta}$ ،

والمأخوذة من المعادلة الجديدة (81.2) تصبح متحيزة وغير متسقة. ويمكن إستعمال

طريقة المتغيرات الأدواتية Instrumental Variables للحصول على مقدرات متسقة. ولكن هذه الطريقة غير مطلوبة في هذه المرحلة من التحليل (سنوضحها بالتفصيل في الفصل الخامس). في هذه المرحلة نستعمل طريقة بديلة للحصول على مقدرات تقاربية للقيمة  $\hat{\beta}$ . فإذا اعتبرنا نهاية احتمال  $\hat{\beta}$  من المعادلة المقدرة والتي هي:

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i^* \dots \dots \dots (2.83)$$

$$\hat{\beta} = \beta + \frac{\sum (X_i^* - \bar{X}) u_i^*}{\sum (X_i^* - \bar{X})^2} \quad \text{فإننا نجد:}$$

و بالتعويض عن:  $X_i^* = X_i + W_i$  وعن  $u_i^* = u_i - \beta W_i$  نجد:

$$\hat{\beta} - \beta = \frac{\sum (X_i - \bar{X}) u_i + \sum W_i u_i - \beta \sum (X_i - \bar{X}) W_i - \beta \sum W_i^2}{\sum (X_i - \bar{X})^2 + 2 \sum (X_i - \bar{X}) W_i + \sum W_i^2} \dots \dots (2.84)$$

تم نقسم البسط والمقام على حجم العينة  $n$ ، ونأخذ نهاية الاحتمال لنجد:

$$\text{plim}(\hat{\beta}) = \beta - \beta \sigma_w^2 / (\sigma_x^2 \pm \sigma_w^2) = \frac{\beta}{1 + \sigma_w^2 / \sigma_x^2} < \beta$$

$$\text{plim}(\hat{\beta} - \beta) < 0 \quad \text{أي أن:}$$

ومنه، فإنه من أجل العينات الكبيرة، تعطي المربعات الصغرى للمقدر  $\hat{\beta}$  مقدرات ناقصة لـ  $\beta$  Underestimate  $\beta$  وذلك إذا كان  $\beta$  موجبا.

لنعتبر الآن المربعات الصغرى لإتحاد  $X^*$  في  $Y$  أي:

$$X_i^* = \gamma_0 + \gamma Y_i + u_i \dots \dots \dots (2.85)$$

و تكون المعادلة التقديرية هي:

$$\hat{X}_i^* = \hat{\gamma}_0 + \hat{\gamma} Y_i$$

لتكون المقدرة  $\hat{\gamma}$  على الشكل:

$$\hat{\gamma} = \frac{\sum (Y_i - \bar{Y}) X_i^*}{\sum (Y_i - \bar{Y})^2}$$

وبالتعويض عن  $Y_i - \bar{Y} = \beta(X_i - \bar{X}) + (u_i - \bar{u})$

وعن  $X_i^* = X_i + W_i$  نجد:

$$\hat{\gamma} = \frac{\beta \sum (X_i - \bar{X}) X_i + \sum X_i (u_i - \bar{u}) + \beta \sum (X_i - \bar{X}) W_i + \sum (u_i - \bar{u}) W_i}{\beta^2 \sum (X_i - \bar{X})^2 + 2\beta \sum (X_i - \bar{X})(u_i - \bar{u}) + \sum (u_i - \bar{u})^2} \dots (2.86)$$

ثم كذلك نقسم البسط والمقام على حجم العينة  $n$  ونأخذ نهاية الاحتمال

لنجد:

$$p\lim(\hat{\gamma}) = \beta \sigma_x^2 / (\beta^2 \sigma_x^2 + \sigma_u^2)$$

وإذا أخذنا معكوس هذه المعلمة كمقدر لآثر  $X$  في  $Y$  نجد:

$$p\lim\left(\frac{1}{\hat{\gamma}}\right) = \beta \left[ 1 + \frac{\sigma_u^2}{\beta^2 \sigma_x^2} \right] > \beta$$

إذا و فقط إذا كانت  $\beta > 0$ .

وبالتالي بالنسبة للعينات الكبيرة تعطى  $\frac{1}{\hat{\gamma}}$  مقدرا زائدا لـ  $\beta$

Overestimate وذلك إذا كان  $\beta$  موجبا. إذا كان  $\beta$  سالبا فإن كل النتائج المتوصل إليها تصبح بالعكس.

## (2) أخطاء القياس في المتغير التابع

لنعتبر ثانية نفس النموذج الكلاسيكي البسيط. ثم نفرض بأن ملاحظات

المتغير التابع تحتوي على أخطاء، ونشاهد عمليا  $Y_i^*$  عوضا عن  $Y_i$ . فإذا كانت هذه الأخطاء عشوائية وعلى الشكل:

$$Y_i^* = Y_i + v_i$$



حيث تمثل  $v_i$  الخطأ الناتج عن قياس قيمة الملاحظة  $Y_i$ . وإذا كانت  $v_i$  تنطبق عليها الفرضيات الأساسية للنموذج البسيط، ومستقلة عن  $X_i$ ،  $u_i$ ، يمكن كتابة المعادلة على الشكل:

$$Y_i^* - v_i = Y_i = \alpha + \beta X_i + u_i$$

و تصبح المعادلة المطلوب تقديرها هي:

$$Y_i^* = \alpha + \beta X_i + u_i^* \dots (2.87)$$

$$u_i^* = v_i + u_i$$

أما المعادلة التقديرية الجديدة فهي:

$$\hat{Y}_i^* = \hat{\alpha} + \hat{\beta} X_i \dots (2.88)$$

$$E(u_i^*) = E(v_i + u_i) = 0$$

حيث أن:

$$E(u_i^* X_i) = 0$$

ومنه فإن  $u_i^*$  له نفس خصائص  $u_i$  ومستقل عن  $X_i$ . وبالتالي فإن المربعات الصغرى العادية للمقدر  $\hat{\beta}$  تكون غير متحيزة ومتسقة. ويمكن كذلك إجراء اختبارات التوزيع  $t$ . حيث يصبح المقدر  $\hat{\beta}$  على الشكل:

$$\begin{aligned} \hat{\beta} &= \beta + \frac{\sum (X_i - \bar{X}) u_i^*}{\sum (X_i - \bar{X})^2} \\ &= \beta + \frac{\sum (X_i - \bar{X}) u_i}{\sum X_i^2} + \frac{\sum (X_i - \bar{X}) v_i}{\sum X_i^2} \end{aligned}$$

و إذا أدخلنا التوقع الرياضي ينتج أن مقدر المربعات الصغرى  $\hat{\beta}$  يكون غير متحيز  $E(\hat{\beta}) = \beta$ . كما أنه إذا كان حجم العينة  $n$  كبيرا، تكون نهاية الاحتمال  $\text{plim}(\hat{\beta}) = \beta$ . إذن نستنتج بأن وجود الأخطاء في قياس المتغير

التابع لا يؤثر في خاصية عدم التحيز لمقدرات المربعات الصغرى، شريطة أن تكون هذه الأخطاء عشوائية ولا تخالف الفرضيات الأساسية للنموذج.

## 9-2 مثال 1.2:

لنأخذ مثالا عن دالة الاستهلاك العائلي في الجزائر خلال الفترة (1967-1989) (10). حيث أن  $Y$  تمثل حجم الاستهلاك الفردي السنوي بالأسعار الحقيقية (11) (بآلاف الدينارات)،  $X$  حجم الدخل الفردي السنوي بالأسعار الحقيقية كذلك.

إن تطبيق فرضية الدخل الدائم لكينز، أين يكون الإتفاق الجاري دالة للدخل الشخصي الجاري على بيانات مأخوذة من الديوان الوطني للإحصائيات وإستعمال قانون المربعات الصغرى العادية يعطي:

$$\hat{Y}_i = -343,15 + 0,96X_i$$

$$S.E \ (140,5) \ (0,032)$$

$$R^2 = 0,976 \quad \overline{R}^2 = 0,975 \quad \hat{\sigma}_u = 144,15$$

$$D-W = 1,3 \quad F_{(1,21)} = 883,5 \quad RSS = 436351,1 \quad n = 23$$

10- دراسة ميدانية قام بها الباحثون د./ أ.سواماس، د./ ب. العباس، السيد ص. تومي سنة 1990

لحساب مركز البحوث في الإقتصاد التطبيقي والتنمية CREAD.

11- سنة الأساس 100-1982

وإذا أردنا تقييم النموذج (أو معادلة الاستهلاك) أعلاه، نقول أنه رغم الإشارة السالبة لحد الكفاف، فإن المعادلة الكينزية تعطي نتائج إيجابية. حيث أن الميل الحدي للإستهلاك هو 0.96. وهذا لا يتعارض مع مبادئ النظرية الاقتصادية ويعني أن 96 % من معدل دخل الفرد الجزائري يذهب للإنفاق على الإستهلاك خلال فترة الدراسة. أي أن زيادة وحدة واحدة في الدخل تؤدي إلى زيادة الإستهلاك بـ 0.96 وحدة والباقي (0.04) يذهب للإدخار.

وإذا إنتقلنا إلى الإختبارات الإحصائية (التقييم الإحصائي للمقدرات) نجد أن مقياس معامل التحديد  $R^2$  يبين لنا بأن 97 % من تغيرات الإستهلاك مشروحة بواسطة تغيرات الدخل، أما الباقي 3 % فهي مشروحة بواسطة عوامل أخرى لا نعرفها (مثل الذوق، العادات والتقاليد وغيرها)، وهذا يعني أن الدخل  $X_i$  يشرح دالة الإستهلاك بصورة جيدة.

أما بالنسبة للأخطاء المعيارية  $SE(.)$ ، فنلاحظ أن المقدرتين مقبولتين إحصائيا، حيث أن نصف المقدرة أكبر من هذه الأخطاء المعيارية كما أشرنا لذلك من قبل، وإذا وضعنا الفرضية:

$$H_0: \beta = 0 \quad v_s: H_A: \beta \neq 0$$

أو

$$H_0: \alpha = 0 \quad v_s: H_A: \alpha \neq 0$$

فإننا نجد:

$$t_{n-2} = t_{21} = \frac{\hat{\beta}}{SE(\hat{\beta})} = 29,723 > t_{21, \frac{\lambda}{2}}^{(12)}$$

$$F_{(1,21)} = \frac{R^2}{1-R^2} (21) = 883,5 = (29,723)^2 > F_{(1,21), \lambda\%}$$

$$t_{21, 0.025} = 2,080$$

$$F_{(1,21), 0.05} = 4,32$$

<sup>-12</sup>  $t$  هي قيمة مأخوذة من الجدول حيث  $\lambda = 5\%$  . ثم إن:



ومنه نرفض  $H_0$  ونقبل  $H_A$  البديلة والقائلة باختلاف الميل الحدي للإستهلاك عن الصفر. و يمكن للقارئ أن يتأكد من نفس الشيء بالنسبة لـ  $\hat{\alpha}$ . أما مجال الثقة للمعلمة  $\beta$  فهو:

$$0,89344 \leq \beta \leq 1,02656$$

ومنه نلاحظ أن  $\beta$  ينتمي إلى مجال ثقة محدود وضيق وهذا دلالة على المعنوية الجيدة للمقدرة  $\hat{\beta}$ . ومنه نقول بناءا على المعطيات المتوفرة لدينا يكون النموذج مقبولا إقتصاديا وإحصائيا.

الدخل من الممتلكات	الدخل من الأجور	الدخل $X_t$	الإستهلاك $Y_t$	المشاهدة
743,6796	1333,028	2797,455	2234,547	1967
812,5031	1447,984	2905,423	2424,721	1968
1342,990	1520,663	2969,562	2449,642	1969
1177,394	1596,318	3187,054	2542,507	1970
1133,064	1675,338	3028,087	2511,127	1971
1169,603	1867,826	3176,691	2791,191	1972
1143,927	1837,917	3198,059	2719,716	1973
1170,528	2145,921	3820,519	3235,041	1974
1490,033	2377,555	3902,434	3493,188	1975
1340,302	2484,995	3929,591	3634,591	1976
1393,627	2605,213	4088,956	3867,699	1977
1444,769	3020,252	4441,601	4157,397	1978
1579,233	3385,728	4697,174	4129,261	1979
1633,334	3732,690	5226,668	4411,876	1980
1639,934	3632,150	5149,393	4655,557	1981
1636,702	3814,171	5319,635	4717,369	1982
1570,255	3997,013	5354,752	4675,372	1983
1540,794	3906,416	5342,200	4953,150	1984
1558,407	3781,727	5429,488	4843,626	1985
1551,420	3805,682	5302,546	4674,287	1986
1647,102	3608,541	4924,375	4255,491	1987
1829,415	غ م	4768,605	4164,950	1988
1832,855	غ م	4746,628	4410,601	1989

المصدر: الديوان الوطني للإحصائيات - سنة الأساس 100-1982

- جدول إحصائي -

## 10-2 سلسلة تمارين حول الفصل الثاني

### التمرين الأول:

ليكن النموذج الخطي البسيط والمزود بالفرضيات الأساسية:

$$Y_i = \alpha + \beta X_i + u_i$$

(1) بين صحة العبارات التالية:

$$i) RSS = TSS - \hat{\beta} \sum x_i^2$$

$$ii) \beta = 0 \Rightarrow R^2 = 0$$

$$iii) RSS = (1 - R^2) \cdot TSS$$

$$iv) t_{n-2} = r / (\sqrt{1 - r^2} / \sqrt{n - 2})$$

$$v) \sum \hat{u}_i \hat{Y}_i = 0$$

(2) إذا حذفنا الحد الثابت في المعادلة أعلاه، أوجد المعادلات الطبيعية للمربعات الصغرى ومقدر الميل، وأحسب تباينه.

(3) يعطى المقدر التالي لـ  $\beta$  وهو  $b = \sum_{i=1}^n Y_i / a_i : \forall a_i \in R^*$

وكذلك مقدر  $\alpha$  كما يلي:  $a = \sum_{i=1}^n W_i Y_i : \forall W_i \in R^*$

(a) تحت أية ظروف أو شروط تكون  $a, b$  مقدرتي  $\alpha, \beta$  على التوالي، غير المتحيزين؟

(b) لما تكون  $a, b$  مقدرتي  $\alpha, \beta$  على التوالي غير المتحيزتين، أوجد تباينيهما بدلالة  $a_i, W_i$ . ثم أوجد أصغر قيمة لتباينيهما وقارنهما مع تبايني  $\hat{\alpha}, \hat{\beta}$  على التوالي. حيث  $\hat{\alpha}, \hat{\beta}$  هما مقدرتي المربعات الصغرى.

(c) بين الشروط التي تجعل  $\hat{\alpha}, \hat{\beta}$  مقدرتين كفؤتين؟



(4) إذا كانت  $E(u_i) = k$ ، حيث  $k$  ثابت، فهل يكون مقدار المربعات الصغرى العادية  $\hat{\beta}$  متحيزا. وما هو تباينه؟ وهل يحافظ على خاصية الكفاءة؟

(5) لنفرض أن العلاقة الحقيقية بين المتغيرين  $Y$  و  $X$  هي على الشكل:

$$Y_i = \alpha + \beta X_i + u_i$$

$$E(u_i) = 0$$

و إذا كان هناك باحث يريد تقدير المعلمة  $\beta$  بواسطة تقدير  $Y$  في  $X$  بدون الحد الثابت ( $\alpha = 0$ ).

(a) بين بأن المقدّر  $\hat{\beta}$  سوف يكون متحيزا ثم اشتق العبارة الجبرية لهذا التحيز.

(b) تحت أية ظروف يكون هذا التحيز مساويا للصفر؟

### التمرين الثاني:

في دراسة لإيجاد العلاقة ما بين مبيعات السيارات ومستوى الأجور والمرتبات الإجمالية في إقتصاد بلد ما، نتوقع بأن المستوى العالي للأجور والمرتبات سيؤدي إلى زيادة المبيعات. وكانت البيانات المتوفرة لدينا شهرية، ابتداء من جانفي 1963 إلى أفريل 1970. وإفترضنا النموذج الإقتصادي التالي:

$$S_i = \alpha + \beta W_i + u_i, \quad i = 1, 2, \dots, n$$

حيث أن  $S_i$  هي مبيعات السيارات شهريا،  $W_i$  مرتبات الموظفين الشهرية. وعند تطبيق قانون المربعات الصغرى حصلنا على:

$$\hat{S}_i = 1767,61 + 7,48 W_i$$

$$SE \quad (238,87) \quad (18,5)$$

$$R^2 = 0,80$$

(a) اشرح المعنى الإقتصادي والإحصائي لقيمتي  $\hat{\alpha}$ ،  $\hat{\beta}$ .

(b) أوجد قيمتي  $V\hat{a}r(\hat{\alpha})$  .  $V\hat{a}r(\hat{\beta})$  . وإختبر صحة الفرضية  $H_0: \beta = 0$  . و أوجد مجال ثقة  $\beta$  عند مستوى معنوية  $\lambda = 5\%$  .

### التمرين الثالث:

في عينة تتكون من 10 ملاحظات سنوية، هناك باحث يريد تقدير دالة الطلب على أجهزة التلفزيون القديمة (المستعملة). لقد إستقرت فكرته على بناء نموذجين مختلفين يمثل الأول دالة الطلب الخطي على هذه الأجهزة. بينما يمثل الثاني دالة مرونة الطلب الثابتة وكانت نتائج هذا الباحث على الشكل التالي:

- دالة الطلب الخطي:

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

$$\hat{Y}_i = 1704 - 22,3 X_i \quad : \quad R^2 = 0,76$$

$$SE \quad (4,4)$$

- دالة مرونة الطلب الثابتة:

$$Y_i = \beta_1 \cdot X_i^{\beta_2} \cdot u_i$$

$$\log \hat{Y}_i = 9,12057 - 0,69 \log X_i \quad : \quad R^2 = 0,99$$

$$SE \quad (0,02)$$

(a) أحسب مرونة السعر لكل دالة.

(b) أحسب قيمة الإحصاءة t لأميال الإنتاج. وعلق على نتائجك.

(c) بإستعمال معلوماتك من النظرية الإقتصادية والإحصائية، ماهي الدالة المفضلة لديك؟

(d) تنبأ بالطلب على أجهزة التلفزيون المستعملة لما يكون السعر هو 8 وحدات:

Y	543	580	618	695	724	812	887	991	1186	1940
X	61	54	50	43	38	36	28	23	19	10

التمرين الرابع:

ليكن النموذج الخطي البسيط والمقدر:

$$\hat{Y}_i = 0,5 + 0,1X_i \quad n = 10, \quad \lambda = 5\%$$

$$SE \quad (0,01) \quad (0,05)$$

- (a) نريد معرفة ما إذا كان المتغير  $X_i$  يفسر حقيقة النموذج  
(b) أوجد حيز الثقة للمعلمة  $\beta$ . والتوقع النقطي لما  $X_i = 10$ .

التمرين الخامس:

لتكن دالة الطلب على الأحذية التي تحمل علامة SONIPEC هي كمايلي:

$$Q_i = \alpha + \beta P_i + u_i \quad : \quad i = 1, 2, \dots, n$$

Q: الكمية. P: السعر

- (a) اشرح المعالم  $\alpha$ ,  $\beta$  وحدد إشارتهما مسبقا.  
(b) ضع قائمة بأسماء المتغيرات المهمة والتي تظن أنها محذوفة من الدالة أعلاه.

التمرين السادس:

يعطى لك النموذج المقدر على الشكل:

$$\hat{Y}_i = 1,38 + 0,12X_i \quad : \quad i = 1, 2, \dots, n$$

$$RSS = 0,6528, \quad \sum x_i^2 = 162, \quad n = 8, \quad \lambda = 5\%$$

أوجد مجال الثقة لـ  $\beta$ . وأختبر الفرضية  $H_0: \beta = 0$ .



### التمرين السابع:

لديك النموذج الخاص بدالة الإستهلاك:

$$\hat{C}_i = 623,28 + 0,402X_i : i = 1, 2, \dots, 80$$

$$SE(147,54) (2,91)$$

إختبر صحة الفرضيتين التاليتين  $H_0: \alpha = 0$ ،  $H_0: \beta = 0$ ، ومارأيك في النموذج؟

لو غيرنا النموذج المقدر إلى النتيجة:

$$\hat{C}_i = -7,37 + 0,9Y_d : i = 1, 2, \dots, 80$$

حيث  $Y_d$  هي الدخل المتاح وكانت لدينا النتائج التالية:

$$\frac{\hat{\beta}}{SE(\hat{\beta})} = 201,23, \frac{\hat{\alpha}}{SE(\hat{\alpha})} = 2,44$$

قم بنفس الإختبارات أعلاه. وماحكمك على النموذج الجديد.

### التمرين الثامن:

يتحدد مستوى الدخل لدى أصحاب المدرسة النقدية بواسطة كمية النقود المعروضة في السوق.

(a) مستعملا البيانات أدناه، إختبر صحة هذه الفرضيات.

(b) إشرح المعنى الإقتصادي والإحصائي لمعالم الإنحدار.

(c) إذا أرادت الحكومة رفع مستوى الدخل (عن طريق زيادة الإنفاق الحكومي مثلا) إلى 2000 وحدة نقدية ففي أي مستوى يكون عرض النقود؟

السنوات	الدخل	كمية النقود
1967	753	175,7
1968	796,3	187,3
1969	868,5	202,2
1970	935,5	208,8
1971	982,4	219,6
1972	1063,4	233,8
1973	1171,1	255,3
1974	1306,6	270,5
1975	1413,2	283,1

التمرين التاسع:

يحتوي الجدول الآتي على الناتج المحلي الإجمالي  $X_i$ ، والطلب على الغذاء  $Y_i$  في دولة متخلفة لمدة عشرة سنوات متتالية.

$Y_i$	6	7	8	10	8	9	10	9	11	10
$X_i$	50	52	55	59	57	58	62	65	68	70

- (a) قدر دالة الطلب على الغذاء و ما هو المعنى الإقتصادي لنتائجك؟
- (b) احسب معامل التحديد و أوجد التغيرات المشروحة وغير المشروحة في الاستهلاك.
- (c) احسب الأخطاء المعيارية لمقدرات النموذج. ثم كون إختبارات المعنوية لمعالم الإنحدار عند  $\lambda = 5\%$ .
- (d) احسب 99 % مجال ثقة لمعالم الإنحدار.

التمرين العاشر:

نريد دراسة العلاقة الموجودة بين إنتاج مؤسسة والساعات الإضافية للعمال ولدينا المعطيات التالية:

عدد الساعات الإضافية	0	1	2	3	4
عدد القطع المنتجة	130	145	160	165	170

إختبر المتغيرات وحدد العلاقة النظرية، ثم قدر النموذج وعلق على نتائجك إقتصاديا وإحصائيا.



## الفصل الثالث: تحليل الإنحدار المتعدد

لنوسع الآن تحليلنا إلى معادلة إنحدار تحتوي على أكثر من متغير مستقل، لكننا نحتفظ بفرضية الشكل الخطي المختصر. حيث يكون المتغير التابع هو المتغير الداخلي الوحيد في المعادلة. إذ سنتحدث في هذا الفصل عن نموذج الإنحدار الذي يحتوي على أكثر من متغير مستقل واحد (بالإضافة إلى الحد الثابت). أما فرضيات النموذج فهي نفسها المذكورة في نموذج الإنحدار الخطي البسيط والمفصلة في الفصل الثاني<sup>(1)</sup>. نبدأ بنموذج إنحدار يحتوي على متغيرين مستقلين حتى نبين كيف يمكن أن تحصل مقدرات المربعات الصغرى لمعالم الإنحدار وكيفية شرحها. و من ثم نوسع هذه المعادلة (ذات متغيرين مستقلين) إلى معادلة ذات  $k$  متغير مستقل ( $k \geq 2$ ) لنرى مشاكل التقدير التي تنتج عن ذلك. وبالتالي نبين ضرورة استعمال المصفوفات في مواصلة تحليلنا لخصائص المربعات الصغرى والنتائج الإحصائية.

### 3-1 نموذج إنحدار بمتغيرين مستقلين

نمدد النموذج البسيط بفرض أن المتغير التابع  $Y$  هو دالة خطية للمتغيرين المستقلين  $X_2, X_3$  وللخطأ العشوائي  $u_i$ . إن هذا النموذج هو مجرد تطوير للنموذج البسيط و منه فلا داعي لإشتقاق كل نتائجنا بالتفصيل ما دامت تحصل بنفس الطريقة المستعملة في الفصل الثاني. و نكتب نموذج الإنحدار الخطي ذو متغيرين مستقلين على الشكل:

---

1- بالإضافة للفرضيات المذكورة في نموذج الإنحدار البسيط، يجب التوضيح بأن قيم المتغيرات المستقلة  $X_j$  ( $j = 1, 2, 3$ ) لا تحتوي على أية علاقة خطية صحيحة فيما بينها وهذا لتحاكي التعدد الخطي فيما بين المتغيرات المستقلة. كما أن عدد الملاحظات يفوق عدد المعالم المطلوب تقديرها في النموذج.

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i ; i = 1, 2, 3, \dots (3.1)$$

حيث أن  $\beta_j$  هي معالم النموذج المطلوب تقديرها، و  $Y$  هو المتغير التابع،  $X_{ji}$  هي متغيرات مستقلة،  $u_i$  هو المتغير العشوائي. فمثلا، تمثل  $X_{2i}$  الملاحظة ( $i$ ) الخاصة بالمتغير المستقل  $X_2$ ،  $\beta_1$  هو الحد الثابت للمعادلة. ويفضل في معظم الحالات كتابة المعادلة (1.3) على الشكل:

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$$

حيث أن  $X_{1i} = 1$  بالنسبة لكل الملاحظات. و يساعدنا الشكل الأخير على سهولة استعمال المصفوفات في تحاليلنا المتطورة أو التي يأتي ذكرها فيما بعد، عند مناقشتنا نموذج الإنحدار الخطي العام (G.L.M) .

### 1-1-3 المعادلات الطبيعية لنموذج ذي متغيرين مستقلين

لنأخذ نموذج المعادلة (1.3) فيكون النموذج التقديري على الشكل:

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} \dots (3.2)$$

حيث أن  $\hat{\beta}_1$ ،  $\hat{\beta}_2$ ،  $\hat{\beta}_3$  هي مقدرات المربعات الصغرى للمعالم  $\beta_1$ ،  $\beta_2$ ،  $\beta_3$  على الترتيب.  $\hat{Y}_i$  هي القيمة التقديرية للمتغير التابع  $Y_i$ . و كما هو معروف، فإن الحصول على هذه المقدرات يكون عن طريق تصغير مجموع مربعات البواقي وهي:

$$RSS = \sum \hat{u}_i^2 = \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})^2 \dots (3.3)$$

و بإشتقاق RSS جزئيا بالنسبة للمعالم غير المعروفة ومساواة نتائجنا للصفر نجد:



$$\frac{\partial \text{RSS}}{\partial \hat{\beta}_1} = -2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i}) = 0$$

$$\frac{\partial \text{RSS}}{\partial \hat{\beta}_2} = -2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i}) X_{2i} = 0$$

$$\frac{\partial \text{RSS}}{\partial \hat{\beta}_3} = -2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i}) X_{3i} = 0$$

و من المشتقات الجزئية الثلاثة أعلاه (والمساوية للصفر) نحصل على المعادلات الطبيعية للمربعات الصغرى العادية و هي:

$$\begin{aligned} \sum Y_i &= n\hat{\beta}_1 + \hat{\beta}_2 \sum X_{2i} + \hat{\beta}_3 \sum X_{3i} \\ \sum Y_i X_{2i} &= \hat{\beta}_1 \sum X_{2i} + \hat{\beta}_2 \sum X_{2i}^2 + \hat{\beta}_3 \sum X_{3i} X_{2i} \dots \dots \dots (3.4) \\ \sum Y_i X_{3i} &= \hat{\beta}_1 \sum X_{3i} + \hat{\beta}_2 \sum X_{2i} X_{3i} + \hat{\beta}_3 \sum X_{3i}^2 \end{aligned}$$

و يمكن تقسيم طرفي المعادلة الأولى في (4.3) على  $n$  الذي يمثل حجم العينة لتعطي:

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}_2 - \hat{\beta}_3 \bar{X}_3 \dots \dots \dots (3.5)$$

و لتبسيط نتائجنا، نأخذ النموذج (1.3) في شكل إنحرافات كميلي:

$$y_i = \beta_2 x_{2i} + \beta_3 x_{3i} + u_i \dots \dots \dots (3.6)$$

حيث أن:  $x_{2i} = X_{2i} - \bar{X}_2$ ،  $x_{3i} = X_{3i} - \bar{X}_3$ ،  $y_i = Y_i - \bar{Y}$  فيكون النموذج التقديري للمعادلة (6.3) هو:

$$\hat{y}_i = \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i} \dots \dots \dots (3.7)$$

أما مجموع مربعات البواقي فهي:

$$\text{RSS} = \sum (y_i - \hat{\beta}_2 x_{2i} - \hat{\beta}_3 x_{3i})^2 \dots \dots \dots (3.8)$$

و للحصول على المعادلات الطبيعية نتبع نفس الخطوات السابقة لنجد:



$$\sum x_{2i} y_i = \hat{\beta}_2 \sum x_{2i}^2 + \hat{\beta}_3 \sum x_{3i} x_{2i}$$

$$\sum x_{3i} y_i = \hat{\beta}_2 \sum x_{2i} x_{3i} + \hat{\beta}_3 \sum x_{3i}^2 \dots \dots \dots (3.9)$$

و تسمى المعادلات (9.3) بالمعادلات الطبيعية للمربعات الصغرى في شكلها الإتحراقي. و لحلها، نضرب المعادلة الأولى بالمقدار  $\sum x_{3i}^2$  و الثانية بالجداء (الحد)  $\sum x_{2i} x_{3i}$  ثم نطرح هذه الأخيرة من الأولى لنجد:

$$\hat{\beta}_2 = \frac{\sum x_{2i} y_i \cdot \sum x_{3i}^2 - \sum x_{3i} y_i \cdot \sum x_{2i} x_{3i}}{\sum x_{2i}^2 \cdot \sum x_{3i}^2 - (\sum x_{2i} x_{3i})^2} \dots \dots \dots (3.10)$$

أما إذا أردنا الحصول على  $\hat{\beta}_3$  فنضرب الأولى بـ  $\sum x_{2i} x_{3i}$  والثانية بـ  $\sum x_{2i}^2$  ونطرح الثانية من الأولى لنجد:

$$\hat{\beta}_3 = \frac{\sum x_{3i} y_i \cdot \sum x_{2i}^2 - \sum x_{2i} y_i \cdot \sum x_{2i} x_{3i}}{\sum x_{2i}^2 \cdot \sum x_{3i}^2 - (\sum x_{2i} x_{3i})^2} \dots \dots \dots (3.11)$$

و من المعادلات الطبيعية (9.3) نجد:

$$\left. \begin{array}{l} \text{i) } \sum \hat{u}_i x_{2i} = \sum x_{2i} \hat{u}_i = 0 \\ \text{ii) } \sum \hat{u}_i x_{3i} = \sum x_{3i} \hat{u}_i = 0 \end{array} \right\} \dots \dots \dots (3.12)$$

إن شرح معالم الإتحدار يتطلب منا توسيع تحليلنا للنموذج المبسط. فمثلا في النموذج (1.3) تقيس المعلمة  $\beta_2$  التغير الحاصل في  $Y$  و المرتبط بتغير وحدة واحدة في المتغير المستقل  $X_2$  بفرض أن كل القيم الأخرى للمتغيرات المستقلة تبقى ثابتة. أما المعلمة  $\beta_3$  فتقيس التغير الحاصل في  $Y$  و المرتبط بتغير  $X_3$  بوحدة واحدة بفرض أن القيم الأخرى تبقى ثابتة و هكذا.

إن في كلتا الحالتين تكون فرضية بقاء المتغيرات المستقلة الأخرى ثابتة أساسية و جوهرية عند شرحنا للمعالم. و تسمى هذه الطريقة بمعالم الإتحدار الجزئي Partial regression coefficient. حيث أن  $\beta_2$ ، مثلا، تقيس أثر  $X_2$  في  $Y$  ولكن مع مراقبة أثر  $X_3$  حتى يبقى ثابتا. نظريا، نحصل على مفهوم خاص عندما نثبت  $X_3$  لزيادة قيم  $X_2$ ، لكن كيف يمكن تطبيق ذلك لما نحصل على مقدار

المربعات الصغرى،  $\hat{\beta}_2$ ، (وفي نفس الوقت على  $\hat{\beta}_3$ )؟. إن الجواب يمكن تحقيقه بحساب المقدرات في النموذجين (1.3) و (6.3)، بواسطة تكوين إنحدارين لنموذجين ذوي متغيرين Two-two variable resgression. و تعميم هذه النتيجة على أي نموذج إنحدار آخر ذو أكثر من متغيرين مستقلين. حيث يعدل الإنحدار الأول المتغير المستقل  $X_2$  (يبقى أثر  $X_3$  ثابتاً)، بينما يقدر الإنحدار الثاني أثر هذا المتغير المعدل على  $Y$  و تجري العملية كما يلي:

### الخطوة الأولى:

حدر  $X_2$  في  $X_3$ . و عندما نقدر المعادلة، نستطيع حساب القيم التقديرية Filted values و البواقي Residuals للنموذج. و للتبسيط نستعمل البيانات المنحرفة (المتغيرات المنحرفة) حيث يكون النموذج المقدر:

$$X_{2i} = \hat{\alpha}X_{3i} + \hat{u}_i$$

$$\hat{X}_{2i} = \hat{\alpha}X_{3i}$$

ومنه ينتج أن:

$$X_{2i} = \hat{X}_{2i} + \hat{u}_i \dots \dots (3.13)$$

$$\hat{u}_i = X_{2i} - \hat{\alpha}X_{3i} = X_{2i} - \hat{X}_{2i} \quad \text{كما أن :}$$

و كذلك نحسب مقدرة المربعات الصغرى  $\hat{\alpha}$  على النحو:

$$\hat{\alpha} = \sum X_{2i}X_{3i} / \sum X_{3i}^2 \dots \dots (3.14)$$

و ينصب إهتمامنا الآن حول البواقي  $\hat{u}_i$ . لأن  $\hat{u}_i$  تمثل ذلك الجزء من

$X_{2i}$  و الذي هو غير مرتبط مع  $X_{3i}$ .

### الخطوة الثانية:

نحدر  $Y_i$  في  $\hat{u}_i$  لنجد:

$$Y_i = \gamma\hat{u}_i + v_i \dots \dots (3.15)$$



حيث أن  $V_i$  هو متغير عشوائي (خطأ عشوائي) جديد، بينما  $\hat{u}_i$  أصبحت متغيراً مستقلاً. و بعد تقدير هذه المعادلة بواسطة المربعات الصغرى العادية نجد:

$$\hat{\gamma} = \sum y_i \hat{u}_i / \sum \hat{u}_i^2 \dots\dots\dots (3.16)$$

حيث تمثل  $\hat{\gamma}$  أثر "  $X_{2i}$  المعدلة " على  $Y_i$ . و إذا كان هذا صحيحاً فإنه ينتج لدينا  $\hat{\gamma} = \hat{\beta}_2$  على النحو التالي:

$$\hat{u}_i = X_{2i} - \hat{\alpha} X_{3i} = X_{2i} - \left[ \frac{\sum X_{2i} X_{3i}}{\sum X_{3i}^2} \right] \cdot X_{3i}$$

و لنعوض ذلك بالمعادلة (16.3) فتصبح:

$$\hat{\gamma} = \sum y_i \hat{u}_i^2 / \sum \hat{u}_i^2 = \frac{\sum X_{2i} Y_i - \left( \frac{\sum X_{2i} X_{3i}}{\sum X_{3i}^2} \right) \cdot \sum X_{3i} Y_i}{\sum X_{2i}^2 + \left( \frac{\sum X_{2i} X_{3i}}{\sum X_{3i}^2} \right)^2 - 2 \left( \frac{\sum X_{2i} X_{3i}}{\sum X_{3i}^2} \right) \sum X_{2i} X_{3i}}$$

و بعد ضرب البسط والمقام بالمقدار  $\sum X_{3i}^2$  و تبسيطها نجد أن  $\hat{\gamma} = \hat{\beta}_2$

### 2-3 توسيع النموذج إلى k متغير مستقل:

نقوم بتوسيع النموذج (1.3) أو (6.3) إلى نموذج يحتوي على k متغير مستقل حيث ( $k > 2$ ) مستعملين طريقة المربعات الصغرى العادية. و منه نبحث عن المعادلات الطبيعية. إن تمديد النموذج إلى k متغير مستقل يكون على الشكل:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots\dots\dots + \beta_k X_{ki} + u_i \dots\dots\dots (3.17)$$

$$i = 1, 2, \dots\dots\dots, n$$

و تحتوي المعادلات الطبيعية على k معادلة طبيعية. و k متغير مستقل. حيث تكون المعالم غير المعروفة هي  $\beta_1, \beta_2, \dots\dots\dots, \beta_k$ . بينما القيم المعروفة هي مجموع مربعات القيم المستقلة و التابعة و كذلك المجاميع الوسيطة فيما بينها.



و لإشتقاق  $k$  معادلة طبيعية بدون إستعمال قانون الإشتقاق الجزئي المذكور سابقا. نكتب معادلة العلاقة المقدرة على الشكل:

$$y_i = \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki} + \hat{u}_i \dots (3.18)$$

و من المعادلة (12.3) لدينا  $\sum \hat{u}_i = 0$  و  $\sum X_{ji} \hat{u}_i = 0$  و بإدخال

المجموع بالنسبة لكل  $i$  في المعادلة (18.3) نحصل على:

$$\sum y_i = \hat{\beta}_2 \sum x_{2i} + \hat{\beta}_3 \sum x_{3i} + \dots + \hat{\beta}_k \sum x_{ki} + \sum \hat{u}_i = 0$$

أما إذا ضربنا المعادلة (18.3) بالمتغير  $x_{2i}$  و جمعنا بالنسبة لكل  $i$

فنحصل على المعادلة الطبيعية الأولى <sup>(2)</sup> على الشكل:

$$\sum y_i x_{2i} = \hat{\beta}_2 \sum x_{2i}^2 + \hat{\beta}_3 \sum x_{2i} x_{3i} + \dots + \hat{\beta}_k \sum x_{2i} x_{ki} \dots (3.19)$$

و نواصل ضرب المعادلة (18.3) بالمتغيرات المستقلة  $x_{ji}$  ( $j \geq 2$ )

كل مرة و نجمعها بالنسبة لكل  $i$  ( $i = 1, 2, \dots, n$ ) لنصل إلى آخر معادلة طبيعية على الشكل:

$$\sum x_{ji} y_i = \hat{\beta}_2 \sum x_{ji} x_{2i} + \hat{\beta}_3 \sum x_{ji} x_{3i} + \dots + \hat{\beta}_k \sum x_{ji}^2 \dots (3.20)$$

إن حل  $(k-1)$  معادلة طبيعية من أجل الحصول على المقدرات  $\hat{\beta}_j$  ( $j = 2, \dots, k$ )

صعب و يتطلب وقتا طويلا. كما أنه نكي نجري إختبارات المعنوية لمعالم الإتحاد

الفردية، من الطبيعي أن نتساءل عن إمكانية تطبيق نظرية Gauss Markov على

النموذج (17.3) و بالتالي نتساءل كذلك عن إمكانية الحصول على توزيعات مقدرات

معالم الإتحاد. إن إشتقاق الخصائص الإحصائية لنموذج الإتحاد المحتوي على

أكثر من متغير مستقل معقد، نوعا ما، بدون إستعمال حساب المصفوفات. و لهذا

سنكتفي ببعض النتائج فقط، و ذلك في إنتظار مناقشة النموذج في شكل

مصفوفات (النموذج الخطي العام) في الفقرات اللاحقة من هذا الفصل.

2- نلاحظ لما يكون النموذج (17.3) في شكله الإحزافي، فإننا نفقد معادلة طبيعية واحدة ويصبح عدد

المعادلات الطبيعية لـ  $k$  متغير هو  $(k-1)$  معادلة.

### 1-2-3 حساب معامل التحديد المضاعف $R^2$ :

عندما يكون لدينا أكثر من متغير مستقل في نموذج الانحدار الخطي، ننتقل من معامل التحديد العادي (مربع معامل الارتباط البسيط) إلى معامل التحديد المضاعف. ونشير هنا إلى أن معامل الارتباط البسيط يقيس العلاقة ما بين متغير مستقل و متغير تابع. و تكون عادة هذه العلاقة محصورة ما بين الصفر و الواحد. أما معامل التحديد فهو يقوم بنفس الدور بالإضافة إلى أنه يمكن أن يدرس العلاقة الموجودة ما بين المتغير التابع  $Y_i$  و عدة متغيرات مستقلة مرة واحدة. و يسمى بمعامل التحديد المضاعف (المتعدد). كما أنه يمكن أن نبين العلاقة الموجودة ما بين متغير مستقل و عدة متغيرات مستقلة أخرى و يسمى بمعامل الارتباط المتعدد. ويستعمل عادة في إختبارات إكتشاف التعدد الخطي (أنظر الفصل الرابع) حيث يعتمد عليه الباحثان Farrar-Glauber في شكل معاملات تحديد جزئية على شكل:

$R^2_{X_1, X_2, \dots, X_k}$  و  $R^2_{X_2, X_1, X_3, \dots, X_k}$ . وعلى العموم نكتب  $R^2_{X_j, X_1, X_2, \dots, X_k}$  حيث أنه يربط ما بين المتغير المستقل  $X_j$  و بقية المتغيرات المستقلة الأخرى من غير  $X_j$ ، و يبين  $R^2$  هنا، نسبة التغير الكلي في  $Y_i$  و المشروحة بواسطة خط الانحدار. ولحساب قيمة  $R^2$  كمقياس لجودة التوفيق في نموذج الانحدار المحتوي على  $k$  متغير مستقل، يمكن إتباع نفس الطريقة المستعملة في الفصل الثاني لنصل إلى:

$$TSS = ESS + RSS$$

ففي النموذج ذي متغيرين مستقلين بالمعادلة (6.3) يمكن حساب  $R^2$  على

الشكل:

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} = \left( \hat{\beta}_2 \sum x_{2i} y_i + \hat{\beta}_3 \sum x_{3i} y_i \right) / \sum y_i^2 \dots (3.21)$$

أما بالنسبة للنموذج المتعدد بالمعادلة (17.3) فيكون:

$$R^2 = \left[ \hat{\beta}_2 \sum x_{2i} y_i + \hat{\beta}_3 \sum x_{3i} y_i + \dots + \hat{\beta}_k \sum x_{ki} y_i \right] / \sum y_i^2 \dots (3.22)$$



إذن نلاحظ دائما بأن  $R^2$  يقيس نسبة التغير في  $Y_i$  و التي تكون مشروحة بواسطة معادلة خط الإنحدار. و هناك مجموعة من المشاكل نواجهها مع استعمال  $R^2$ . فأولا، كل نتائجنا الإحصائية تأتي من الفرضية القائلة بأن نموذجنا المبني في المعادلة (17.3) يكون صحيحا، ثم ليس لدينا طريقة أو قيمة إحصائية بديلة للمقارنة بها. ثانيا، إن  $R^2$  حساس لعدد المتغيرات المستقلة و الموجودة بالنموذج، حيث أن إضافة متغيرات مستقلة أخرى لمعادلة الإنحدار لا يمكن أبدا أن تقلل من قيمة  $R^2$ . و بالعكس فإنها يمكن أن تزيد من قيمته (لأن إضافة متغير مستقل جديد للنموذج (17.3) لا يؤثر في التغيرات الكلية TSS، و لكن يزيد في قيمة الإنحرافات المشروحة ESS). و بالتالي فإن تعظيم  $R^2$  يكون بواسطة زيادة متغيرات مستقلة للنموذج الأصلي، و يصبح تفسير و استعمال  $R^2$  صعبا عندما يكون النموذج بدون الحد الثابت، حيث ليس بالضرورة في هذه الحالة أن يكون  $R^2 = ESS/TSS$  محصورا ما بين الصفر و الواحد. إن الصعوبة مع  $R^2$  كمقياس لجودة التوفيق هو أنه يعتمد على التغيرات الحاصلة في المتغير التابع  $Y_i$  (التغيرات المشروحة و غير المشروحة). و بالتالي لا يأخذ عدد درجات الحرية بعين الاعتبار في أي شكل إحصائي.

و نخلص إلى أنه كلما أضفنا متغيرات مستقلة لنموذج الإنحدار، كلما ارتفعت قيمة  $R^2$ ، و كذلك قيمة مجموع الإنحرافات المشروحة ESS. بينما RSS تنخفض قيمته و سوف نتطرق لهذا الموضوع بالفصل القادم (إضافة محدرات جديدة للنموذج) Variable addition.

بعد ملاحظة أن إضافة متغيرات مستقلة للنموذج لا يمكن أن تقلل من قيمة  $R^2$ ، بل عادة، ما تزداد هذه القيمة، لأن قيمة البسط في المعادلة (22.3) تزداد بينما يبقى المقام TSS على حاله. و لتصحيح ذلك نعدل  $R^2$  آخذين بعين الاعتبار درجات الحرية (و التي يقل عددها بإضافة متغيرات مستقلة جديدة للنموذج الأصلي). و إذا كان تعريف  $R^2$  هو:



$$R^2 = 1 - \frac{RSS/n}{TSS/n} = 1 - \frac{RSS}{TSS}$$

فإن تعريف  $\bar{R}^2$  هو:

$$\bar{R}^2 = 1 - \frac{RSS/(n-k)}{TSS/(n-1)} \quad (3.23) \dots\dots (3)$$

و يسمى بمعامل التحديد المصحح.

و بتعويض بسيط نجد:

$$\bar{R}^2 = 1 - (1 - R^2) \cdot \frac{n-1}{n-k} \dots\dots (3.24)$$

و من المعادلة الأخيرة أعلاه، تظهر العلاقة بين  $R^2$  و  $\bar{R}^2$  حيث أن:

$$(1) \quad R^2 = \bar{R}^2 \text{ إذا كانت } k = 1$$

$$(2) \quad R^2 \geq \bar{R}^2 \text{ إذا كانت } k > 1$$

$$(3) \quad \text{يمكن أن يأخذ } \bar{R}^2 \text{ قيما سالبة.}$$

إذا كان حجم العينة  $n$  كبيرا، فإن  $R^2$  و  $\bar{R}^2$  يقتربان في قيمتهما. لكن في العينات الصغيرة، إذا كان عدد المتغيرات المستقلة كبيرا ( $n \geq k$ ) بالمقارنة مع حجم العينة، فإن  $\bar{R}^2$  يقل بكثير عن  $R^2$ ، و يمكن أن يأخذ قيما سالبة في هذه الحالة. و بالتالي يجب شرحه على أساس أن قيمته تساوي الصفر إذا حدث ذلك.

إن  $\bar{R}^2$  له مجموعة من الخصائص تجعله وسيلة قياس جودة التوفيق أفضل من  $R^2$ . حيث عندما نضيف متغيرات جديدة للنموذج تزداد قيمة  $R^2$ ، بينما نجد قيمة  $\bar{R}^2$  يمكن أن تزيد أو تنقص و ذلك تبعا لأهمية المتغيرات المستقلة المضافة للنموذج. إن استعمال المقياس الجديد  $\bar{R}^2$  يقضي على الأقل، على تساؤلات

<sup>3</sup> - نقسم TSS على  $(n-1)$  لأن درجة حرية واحدة استعملت في حساب  $\bar{Y}$  ونقسم RSS على  $(n-k)$

لأن  $k$  معلمة استعملت وقدرت في النموذج قبل الحصول على RSS كما هو موضوع بالمعادلة (37.2)

من الفصل الثاني.

بعض الباحثين حول أهمية زيادة عدد المتغيرات للنموذج بدون التفكير في سبب ظهور هذه المتغيرات. على كل حال، لا يجب التفكير في أن  $\bar{R}^2$  يحل كل المشاكل المتعلقة بالمقياس  $R^2$  كمقياس لجودة التوفيق. حيث أن القرار حول إمكانية ظهور بعض المتغيرات في النموذج أم لا، تبقى معتمدة على إعتبارات نظرية أخرى في القياس الإقتصادي. كما أن القيمة العددية لـ  $\bar{R}^2$  تكون جد حساسة لنوع المعطيات (البيانات) المستعملة.

### 3-3 النموذج الخطي العام (GLM) General Linear Model :

نظرا لمشاكل التحليل و الاختبار الإحصائي التي تواجهها في دراسة خصائص مقدرات المربعات الصغرى للنموذج (17.3) فإننا نعيد صياغته على الشكل:

$$Y_i = \sum_{j=1}^k \beta_j X_{ji} + u_i \quad : \quad i = 1, 2, \dots, n \dots (3.25)$$

حيث أن  $X_{ji} = 1$  من أجل كل  $i$ ، ليكون الحد الثابت هو  $\beta_1$ ، إن هذا الشكل معمم أكثر ما دام يعطي الحالة التي لا تحتوي على حد ثابت. و نكتب المعادلة (25.3) بالنسبة لـ  $n$  ملاحظة في شكل مصفوفات:

$$Y = X\beta + U \dots (3.26)$$

حيث أن  $Y$  و  $U$  هما  $n \times 1$  موجهين عموديين،  $X$  هي  $n \times k$  مصفوفة متغيرات مستقلة بحيث أن  $n \geq k$  و رتبة  $X$  تساوي  $k$  (أي  $\text{Rank}(X) = k$ ) لتجاوز مشاكل التعدد الخطي. أما  $\beta$  فهي  $k \times 1$  موجه عمودي للمعالم غير المعروفة. و نكتب:

$$\tilde{Y} = \begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix}, \quad \tilde{X} = \begin{bmatrix} X_{11} & X_{21} & \dots & \dots & \dots & X_{k1} \\ X_{12} & X_{22} & \dots & \dots & \dots & X_{k2} \\ \vdots & \vdots & & & & \vdots \\ \vdots & \vdots & & & & \vdots \\ X_{1n} & X_{2n} & \dots & \dots & \dots & X_{kn} \end{bmatrix},$$

$$\tilde{\beta} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_k \end{bmatrix}, \quad \tilde{U} = \begin{bmatrix} U_1 \\ \vdots \\ U_n \end{bmatrix}$$

و هي الصيغة المتعارف عليها في القياس الإقتصادي بالنسبة للنموذج الخطي العام. و يكون المشكل الأساسي هو الحصول على مقدر لموجه المعالم غير المعروفة  $\beta$ . ومنه يمكن إعادة صياغة الفرضيات الأساسية للنموذج (و المذكورة سابقا) و التي تناسب النموذج الخطي العام و هي:

(1) إن كل ملاحظات موجه المتغير العشوائي  $U$  لها وسط مساو للصفر

$$E(\tilde{U}) = \tilde{0}$$

(2) تكون تباينات الأخطاء العشوائية متجانسة بالنسبة لكل الملاحظات. أما التباينات المشتركة فهي معدومة بالنسبة لكل الملاحظات المختلفة أي:

$$E(\tilde{U}\tilde{U}') = \sigma_u^2 I_n$$

حيث أن  $I_n$  هي مصفوفة الوحدة.

(3) تكون قيم المتغيرات المستقلة  $X_{ji}$  غير عشوائية، أي أن  $X$  مصفوفة غير عشوائية. كما أنه لا توجد أية علاقة خطية صحيحة فيما بين المتغيرات

المستقلة  $X_{ji}$  أي أن:  $\text{Rank}(X) = k \leq n$



4) تتبع الأخطاء العشوائية قانون التوزيع الطبيعي المتعدد Multivariate أي أن:

$$\tilde{U} \sim IN(0, \sigma_u^2 I_n)$$

إن الفرضيات الخاصة بالخطأ العشوائي هي أقوى ما يمكن، حتى تضمن الإحصائيات والخصائص الحسابية لمقدرات المربعات الصغرى العادية. و تكون مصفوفة التباين-التباين المشترك للأخطاء كما يلي:

$$E(\tilde{U}\tilde{U}') = \begin{bmatrix} E(U_1^2) & E(U_1U_2) & \dots & \dots & \dots & E(U_1U_n) \\ E(U_2U_1) & E(U_2^2) & \dots & \dots & \dots & E(U_2U_n) \\ \vdots & \vdots & & & & \vdots \\ \vdots & \vdots & & & & \vdots \\ E(U_nU_1) & E(U_nU_2) & \dots & \dots & \dots & E(U_n^2) \end{bmatrix}$$

$$= \begin{bmatrix} \text{var}(U_1) & \text{cov}(U_1, U_2) & \dots & \dots & \dots & \text{cov}(U_1, U_n) \\ \text{cov}(U_2, U_1) & \text{var}(U_2) & \dots & \dots & \dots & \text{cov}(U_2, U_n) \\ \vdots & \vdots & & & & \vdots \\ \vdots & \vdots & & & & \vdots \\ \text{cov}(U_n, U_1) & \text{cov}(U_n, U_2) & \dots & \dots & \dots & \text{var}(U_n) \end{bmatrix}$$

$$= \sigma_u^2 \begin{bmatrix} 1 & 0 & \dots & \dots & 0 \\ 0 & \ddots & \dots & \dots & 0 \\ \vdots & & \ddots & & \vdots \\ \vdots & & & \ddots & 0 \\ 0 & \dots & \dots & 0 & 1 \end{bmatrix} = \sigma_u^2 I_n$$

إن النموذج التقديري للمعادلة (26.3) (بتوسيع طبيعي وبسيط لنموذج

الفصل الثاني) يكون على الشكل:

$$\hat{Y} = X\hat{\beta} \dots \dots (3.27)$$

حيث أن  $\hat{\beta}$  هو موجه المعالم المقدرة،  $\hat{Y}$  هو  $1 \times n$  موجه عمود القيم التقديرية. أما موجه عمود البواقي فهو:

$$\hat{U} = Y - \hat{Y} = Y - X\hat{\beta} \dots (3.28)$$

و يتم الحصول على موجه مقدرات المعالم  $\hat{\beta}$  عن طريق تصغير RSS، وذلك عن طريق اشتقاق هذه الأخيرة (RSS)، جزئيا بالنسبة للموجه  $\hat{\beta}$ .

$$RSS = \hat{U}'\hat{U} = \sum \hat{U}_i^2 = (Y - X\hat{\beta})'(Y - X\hat{\beta})$$

$$RSS = Y'Y - 2\hat{\beta}'X'Y + \hat{\beta}X'X\hat{\beta} \dots (3.29)$$

حيث لدينا المقدارين  $\hat{\beta}'X'Y$  و  $Y'X\hat{\beta}$  هما عدنان سنميان ومتساويان لينتج أن:

$$\frac{\partial(RSS)}{\partial \hat{\beta}} = -2X'Y + 2X'X\hat{\beta} = 0$$

و هو الشرط الضروري من أجل الوصول إلى نقطة الإستقرار. أما إذا اشتقينا ثانية المعادلة أعلاه فنجد:

$$\frac{\partial^2(RSS)}{\partial \hat{\beta} \partial \hat{\beta}'} = 2X'X > 0$$

و بالإعتماد على الفرضية الثالثة تكون رتبة  $X$  تامة و منه تكون المصفوفة  $X'X$  غير شاذة لينتج:

$$X'Y = X'X\hat{\beta} \dots (3.30)$$

و هي المعادلات الطبيعية للمربعات الصغرى. و يكون المقدر  $\hat{\beta}$ :

$$\hat{\beta} = (X'X)^{-1}X'Y \dots (3.31)$$

و من خصائص المربعات الصغرى العادية (OLS) ينتج:

$$X'\hat{U} = X'(Y - X\hat{\beta}) = X'Y - X'X\hat{\beta} = 0 \dots (3.32)$$

و هذا معناه أن مجموع جداءات المتغيرات المستقلة و البواقي يعطي الصفر. أي أن موجه عمود البواقي و مصفوفة المتغيرات المستقلة متعامدين، وذلك لأن قيم  $X$  مثبتة ( $E(X'U) = 0$ ). حيث تعتبر هذه النتيجة أساسية في المربعات الصغرى. و يعطي أول عنصر من المعادلة (32.3) النتيجة  $\bar{U} = 0$ . وهذا يعني أن بواقي المربعات الصغرى لها دائما وسط مساو للصفر، شريطة أن تحتوي تلك المعادلة على الحد الثابت<sup>(4)</sup>. كما أن  $RSS$  المعرفة في المعادلة (29.3) تصبح على الشكل:

$$RSS = Y'Y - \hat{\beta}X'Y \dots\dots (3.33)$$

### 3-4 الخصائص الإحصائية لمقدرات المربعات الصغرى:

إذا أخذنا المعادلة (31.3) و عوضنا عن  $Y$  نجد:

$$\hat{\beta} = \beta + (X'X)^{-1} X'U$$

$$\hat{\beta} = \beta + AU \dots\dots\dots (3.34)$$

حيث أن  $A = (X'X)^{-1} X'$  و بإدخال التوقع نجد:

$$E(\hat{\beta}) = \beta + AE(U) = \beta$$

و منه فإن:

$$E(\hat{\beta} - \beta) = 0 \dots\dots (3.35)$$

و منه فإن موجه مقدرات المربعات الصغرى العادية  $\hat{\beta}$  هو مقدر خطي وغير متحيز. حيث أنه دالة خطية لموجه الأخطاء  $U$ . أو نقول أن  $(\hat{\beta} - \beta)$  تمثل إنحدار موجه الأخطاء  $U$  في مصفوفة المتغيرات المستقلة  $X$ . وبالتالي إذا كانت آثار المتغيرات المحذوفة موزعة عشوائيا، و مستقلة عن  $X$ ، و لها وسط يساوي

4- إذا إختفى الحد الثابت من معادلة الإنحدار الخطي، فإن  $\bar{U} \neq 0$ .



الصفر، فإن مقدرات المربعات الصغرى تكون غير متحيزة مثلما هو مبين بالمعادلة (35.3). أما مصفوفة التباين-التباين المشترك لـ  $\hat{\beta}$  فهي:

$$\text{var-cov}(\hat{\beta}) = V = E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)']$$

$$V = \begin{bmatrix} \text{Var}(\hat{\beta}_1) & \text{cov}(\hat{\beta}_1, \hat{\beta}_2) & \dots & \dots & \text{cov}(\hat{\beta}_1, \hat{\beta}_k) \\ \text{cov}(\hat{\beta}_2, \hat{\beta}_1) & \text{Var}(\hat{\beta}_2) & \dots & \dots & \text{cov}(\hat{\beta}_2, \hat{\beta}_k) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \text{cov}(\hat{\beta}_k, \hat{\beta}_1) & \text{cov}(\hat{\beta}_k, \hat{\beta}_2) & \dots & \dots & \text{Var}(\hat{\beta}_k) \end{bmatrix} \dots (3.36)$$

إن وحدات القطر الخاصة بالمصفوفة  $V$  تمثل تباينات مقدرات المعالم. بينما تمثل الوحدات الموجودة خارج القطر التباينات المشتركة لمختلف المقدرات، كما أن المصفوفة  $V$  هي مصفوفة متناظرة، حيث أن عناصر قطرها يمكن ألا تكون متساوية، بينما العناصر الموجودة أعلى القطر هي نفسها تلك الموجودة أسفل القطر. إذ أن:

$$\text{cov}(\hat{\beta}_i, \hat{\beta}_j) = \text{cov}(\hat{\beta}_j, \hat{\beta}_i) \quad , \quad i \neq j$$

$$i, j = 1, 2, \dots, k$$

و بالعودة للمعادلة (34.3) نجد:

$$V = E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)'] = E[AUU'A'] = \sigma_u^2 AA' = \sigma_u^2 (X'X)^{-1}$$

و منه نكتب للتبسيط:

$$\text{var}(\hat{\beta}) = \sigma_u^2 (X'X)^{-1} \dots (3.37)$$

و إذا كان موجه الأخطاء  $U$  يتبع التوزيع الطبيعي المتعدد، فإن  $\hat{\beta}$  هو دالة لهذا الموجه. وبالتالي يكون له توزيع طبيعي متعدد أي:

$$\hat{\beta} \sim \text{IN}(\beta, \sigma_u^2 (X'X)^{-1})$$

إن النتيجة المهمة في طريقة المربعات الصغرى أو نظرية Gauss-Markov هي أن الموجه  $\hat{\beta}$  ينتمي إلى مجموعة المقدرات الخطية غير المتحيزة وذات أصغر تباين بالمقارنة مع بقية المقدرات الخطية و غير المتحيزة الأخرى. و نعرف من جديد مقدر المربعات الصغرى العادية  $\hat{\beta}(OLS)$  من المعادلة (31.3) على الشكل:

$$\hat{\beta} = (X'X)^{-1} X'Y = AY$$

بينما نعرف موجه مقدرات آخر هو خطي:

$$b = (A + C)Y = AY + CY \dots (3.38)$$

حيث  $C$  هي مصفوفة ثوابت. و لكي يكون  $b$  مقدرًا غير متحيز لـ  $\beta$  يجب أن يتحقق الشرط:  $E(b) = \beta$  أي:

$$b = (A + C)Y = \beta + CX\beta + (A + C)U$$

$$E(b) = \beta + CX\beta = \beta \quad \text{ومنه فإن:}$$

إذا و فقط إذا كانت  $CX = 0$  كشرط ضروري لذلك. و يصبح تعريف  $b$ :

$$b = \beta + (A + C)U$$

ليكون تباينه هو:

$$\text{var}(b) = E[(b - \beta)(b - \beta)']$$

$$= \sigma_u^2 (A + C)(A + C)' = \sigma_u^2 (X'X)^{-1} + \sigma_u^2 CC'$$

$$CA' = CX(X'X)^{-1} = AC' = 0$$

لأن

$$\text{var}(b) - \text{var}(\hat{\beta}) = \sigma_u^2 CC'$$

ومنه يكون:

و نلاحظ أن المصفوفة  $CC'$  هي مصفوفة على الأقل موجبة شبه محددة

Positif Semi-Definite (P.S.D). و الحالة الوحيدة التي تكون فيها الصيغة

التربيعية  $CC'$  معدومة هي لما  $C = 0$ . و منه يكون مقدر المربعات الصغرى

العادية،  $\hat{\beta}$ ، هو أفضل مقدر خطي غير متحيز أي له خاصية BLUE لتتحقق:

$$\text{var}(b) - \text{var}(\hat{\beta}) = \sigma_u^2 CC' \geq 0$$



إن المقدّر غير المتحيز لتباين الأخطاء  $\sigma_u^2$ ، يعطى عن طريق تقسيم RSS على درجات الحرية المتبقية من التقدير أي:

$$\hat{\sigma}_u^2 = \frac{\hat{U}'\hat{U}}{n-k} = \frac{RSS}{n-k} \dots\dots (3.39)$$

حيث لدينا من معادلة البواقي:  $\hat{U} = Y - X\hat{\beta}$ ، و بالتعويض عن قيمة  $\hat{\beta}$  من (31.3) نجد:

$$\hat{U} = [I - X(X'X)^{-1}X']Y = [I - XA]Y = MY$$

حيث أن  $M = I - X(X'X)^{-1}X'$  و هي مصفوفة متناظرة وخاملة (معدومة القوى) و تحقق الخاصية،  $MX = 0$ . و إذا عوضنا عن Y من المعادلة (26.3) نجد:

$$\hat{U} = MY = MU \dots\dots (3.40)$$

و هذا يعني أن البواقي المشاهدة هي دوال خطية للأخطاء غير المعروفة U. و تكون:

$$RSS = \hat{U}'\hat{U} = U'MU$$

و إذا أخذنا التوقع الرياضي لطرفي المعادلة أعلاه ينتج:

$$E(RSS) = E[U'MU] = E[\text{trace}(U'MU)]$$

$$= \text{trace}[ME(UU')] = \sigma_u^2 \text{trace}(M)$$

$$= \sigma_u^2 [\text{trace}(I_n) - \text{trace}(X(X'X)^{-1}X')]$$

$$= \sigma_u^2 [\text{trace}(I_n) - \text{trace}(I_k)]$$

$$= \sigma_u^2 (n - k)$$

$$\sigma_u^2 = \frac{E(RSS)}{n - k}$$

لنجد أن:

$$\hat{\sigma}_u^2 = \frac{RSS}{n - k}$$

أي أن:



و منه نقول أن  $\hat{\sigma}_u^2$  هو مقدار المربعات الصغرى العادية لتباين الأخطاء، و هو مقدار غير متحيز لـ  $\sigma_u^2$ .

### النموذج في شكله الإتحراقي

لنعرف المصفوفة التالية:

$$M_0 = I - \frac{1}{n} ii' \dots (3.41)$$

حيث أن  $i$  موجه عمود  $n \times 1$ ، تتكون عناصره من القيمة واحد أي:

$$i' = (1 \ 1 \dots, 1)$$

$$\frac{1}{n} i' Y = \frac{1}{n} (1, 1, \dots, 1) \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} = \bar{Y} \quad \text{و منه فإن:}$$

لتكون مثلا:

$$M_0 Y = Y - i \bar{Y} = [(Y_1 - \bar{Y}), (Y_2 - \bar{Y}), \dots, (Y_n - \bar{Y})]'$$

و نقول أن ضرب أي موجه عمود من الملاحظات بالمصفوفة  $M_0$  سوف يعطي موجهها عموديا لتلك الملاحظات في شكلها الإتحراقي. حيث أن المصفوفة  $M_0$  هي مصفوفة متناظرة و خاملة Idempotent، و لها الخصائص التالية:

$$M_0 i = 0 \dots (3.42)$$

$$M_0 \hat{U} = \hat{U} \dots (3.43)$$

إن مشاهدات المتغير التابع  $Y$  معرفة على الشكل  $Y = \hat{Y} + \hat{U}$ . وإذا

عرفنا  $\hat{Y}$  على النحو:

$$\hat{Y} = X\hat{\beta} = \begin{bmatrix} i & : & X_0 \end{bmatrix} \begin{bmatrix} \hat{\beta}_1 \\ \dots \\ \hat{\beta}_0 \end{bmatrix} = \hat{\beta}_1 i + X_0 \hat{\beta}_0 \dots (3.44)$$

حيث أن المصفوفة  $X_0$  هي عبارة عن الموجهات  $X_j$  ( $j = 2, 3, \dots, k$ )

$$n \times (k-1): X_0 = \begin{bmatrix} X_2 & X_3 & \dots & X_k \end{bmatrix} \quad \text{أي}$$

$$(k-1) \times 1 \quad \hat{\beta}_0 = \begin{bmatrix} \hat{\beta}_2 & \hat{\beta}_3 & \dots & \hat{\beta}_k \end{bmatrix} \quad \text{و كذلك لدينا:}$$

و منه نعيد كتابة المعادلة على الشكل:

$$Y = i\hat{\beta}_1 + X_0\hat{\beta}_0 + \hat{U} \dots (3.45)$$

و لنضرب المعادلة (3.45) بالمصفوفة  $M_0$  لنجد:

$$M_0 Y = M_0 X_0 \hat{\beta}_0 + \hat{U} \dots (3.46)$$

ثم نضرب من جديد المعادلة (3.46) بالمصفوفة  $X_0'$  فينتج:

$$X_0' M_0 Y = X_0' M_0 X_0 \hat{\beta}_0 \dots (3.47)$$

و نظرا إلى أن  $M_0$  متناظرة و خاملة فإن:

$$(M_0 X_0)' (M_0 Y) = (M_0 X_0)' (M_0 X_0) \hat{\beta}_0 \dots (3.48)$$

و نلاحظ أن المعادلة (3.48) تمثل مجموعة معادلات طبيعية للمربعات

الصغرى في شكلها الإنحرافي. كما أنه من المعادلة (3.46)، و من تعريف  $M_0$  ينتج:

$$Y' M_0 Y = \hat{\beta}_0' X_0' M_0 X_0 \hat{\beta}_0 + \hat{U}' \hat{U} \dots (3.49)$$

$$TSS = ESS + RSS$$

$$\hat{\beta}_0' X_0' M_0 \hat{U} = \hat{U}' M_0 X_0 \hat{\beta}_0 = 0 \quad \text{لأن:}$$

و منه يصبح معامل التحديد المتعدد (المضاعف) على الشكل:

$$R^2 = 1 - \frac{RSS}{TSS} = 1 - \frac{\hat{U}'\hat{U}}{Y'M_0Y} = 1 - \frac{U'MU}{Y'M_0Y} \dots\dots(3.50)$$

أو على الشكل:

$$R^2 = \frac{ESS}{TSS} = \frac{\hat{\beta}'_0 X'_0 M_0 X_0 \hat{\beta}_0}{Y'M_0Y} = \frac{\hat{\beta}'_0 X'_0 M_0 Y}{Y'M_0Y} \dots\dots(3.51)$$

و ذلك بإستعمال المعادلة (47.3). أما معامل التحديد المصحح فهو:

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n-1}{n-k} = 1 - \frac{RSS/(n-k)}{Y'M_0Y/(n-1)} \dots\dots(3.52)$$

و بمقارنة بسيطة مع النتائج المحصلة من قبل نجد أن:

$$Y'Y = \sum Y_i^2$$

$$Y'M_0Y = \sum (Y_i - \bar{Y})^2 = Y'Y - n\bar{Y}^2$$

و لذا عندما نعود للمعادلة (44.3) نجد أن:

$$\begin{aligned} Y'Y &= \hat{Y}'\hat{Y} + \hat{U}'\hat{U} \\ &= \hat{\beta}'_0 X'_0 X_0 \hat{\beta}_0 + \hat{U}'\hat{U} \end{aligned}$$

و ما دام لدينا الخاصية  $\hat{Y}'\hat{U} = X'\hat{U} = 0$  وكذلك  $\bar{Y} = \bar{\hat{Y}}$  <sup>(5)</sup>. فإن:

$$(Y'Y - n\bar{Y}^2) = (\hat{Y}'\hat{Y} - n\bar{\hat{Y}}^2) + \hat{U}'\hat{U} \dots\dots(3.53)$$

$$TSS = ESS + RSS$$

أما عند حذف الحد الثابت من النموذج (26.3) فإن:  $\bar{Y} = \bar{\hat{Y}} + \bar{\hat{U}} \neq \bar{\hat{Y}}$

$$\bar{\hat{U}} \neq 0 \quad \text{لأن}$$

<sup>5</sup>- في نموذج يحتوي على حد ثابت و لكن إذا كان وسط المتغير التابع  $Y$  مساو للصفر، تكون

المعادلة (53.3) على الشكل:  $Y'Y = \hat{Y}'\hat{Y} + \hat{U}'\hat{U}$ .



و منه تصبح التجزئة في المعادلة (53.3) أعلاه، غير صحيحة، و بالتالي يصبح استعمال  $R^2$  كمقياس لجودة التوفيق غير مفيد.

### 3-5 الإستنباط الإحصائي لمقدرات المربعات الصغرى.

بإدخال قانون التوزيع الطبيعي المتعدد و الموجود بالفرضية الرابعة للنموذج الخطي العام، نقول، نظرا إلى أن موجه مقدرات المربعات الصغرى  $\hat{\beta}$  هو دالة خطية لموجه الأخطاء العشوائية، فإن هذا المقدر له صفة المتغير العشوائي ويتبع كذلك قانون التوزيع الطبيعي المتعدد. حيث أن:

$$\hat{\beta} = \beta + AU$$

و منه فإن:

$$\hat{\beta} \sim N(\beta, \sigma_u^2 (X'X)^{-1})$$

ثم لدينا بواقي المربعات الصغرى هي  $\hat{U} = MU$  إذ أن:

$$\hat{U}'\hat{U} = U'MU$$

$$\frac{\hat{U}'\hat{U}}{\sigma_u^2} = \frac{U'MU}{\sigma_u^2} = \frac{(n-k)\hat{\sigma}_u^2}{\sigma_u^2} \sim \chi_{n-k}^2$$

حيث أن  $\text{Rank}(M)^{(6)} = \text{trace}(M) = n - k$

و مع الخاصية  $MX = 0$ ، يكون الموجهان  $\hat{\beta}$ ،  $\hat{U}$  يتبعان التوزيع الطبيعي المتعدد و مستقلين عن بعضهما البعض، و بالتالي فهما موجهان متعامدان حيث.

<sup>6</sup>- تكون العلاقة  $\text{Rank}(M) = \text{trace}(M)$  صحيحة فقط لما نتعامل مع المصفوفات الخاملة.

$$\text{cov}(\hat{U}, \hat{\beta}) = E \left[ \hat{U}(\hat{\beta} - \beta)' \right] = E[MUU'A']$$

$$= \sigma_u^2 MA = 0, \quad MX = 0$$

و منه نستنتج أن موجه المقدرات  $\hat{\beta}$  مستقل كذلك عن  $\hat{U}'\hat{U}$  و الذي يستلزم أن  $\hat{\beta}$  موزع إستقلاليا عن  $RSS/\sigma_u^2$  (أو  $\hat{\sigma}_u^2$ ) ونكتب:

$$\hat{\beta}_j \sim N(\beta_j, \sigma_u^2 a_{jj}), \quad j = 1, 2, \dots, k$$

حيث أن  $a_{jj}$  هو العنصر  $j$  الموجود بالقطر للمصفوفة  $AA'$  (أو  $(X'X)^{-1}$ ) ولدينا كذلك:

$$(\hat{\beta}_j - \beta_j) \sim N(0, \sigma_u^2 a_{jj})$$

$$\frac{\hat{\beta}_j - \beta_j}{\sigma_u \sqrt{a_{jj}}} \sim N(0, 1)$$

و ليصبح قانون التوزيع  $t$  على الشكل:

$$t = \frac{N(0, 1)}{\sqrt{\chi^2_{n-k} / (n-k)}} = \frac{\hat{\beta}_j - \beta_j}{\sigma_u \sqrt{a_{jj}}} / \sqrt{\frac{(n-k)\hat{\sigma}_u^2}{\sigma_u^2} / (n-k)}$$

و نجد بعد الإختصار:

$$t = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_u \sqrt{a_{jj}}} = \frac{\hat{\beta}_j - \beta_j}{SE(\hat{\beta}_j)} \sim t_{n-k} \dots \dots (3.54)$$

و تساعدنا المعادلة (54.3) على تكوين مجالات الثقة لمعالم الانحدار الفردي بنفس الطريقة المذكورة بالفصل الثاني. و لإجراء إختبار الفرضيات حول قيمة معلمة معينة ( $\beta_j$  مثلا)، نقارن قيمة  $t_{n-k}$  المحسوبة أعلاه مع قيم  $t^*$  المجدولة

(بمستوى معنوية معين). فإذا كانت القيمة المحسوبة أكبر "بالقيمة المطلقة" من القيمة المجدولة، نرفض فرضية العدم  $H_0$  و العكس بالعكس.

### إختبار الفرضيات:

لإجراء الإختبارات الإحصائية حول معنوية معالم النموذج، يفضل الإحصائيون في بعض الأحيان إدخال قيود على معالم نموذج الإنحدار و ذلك لحل بعض المشاكل المطروحة أثناء التحليل. لكن عمليا، ليس من السهل إعتبار هذه الطريقة صحيحة أو ناجحة، حيث أن فرض قيود على معالم النموذج يمكن أن يطرح مشاكل ثانوية أخرى من الناحية الإقتصادية و الإحصائية. فإذا كانت هذه القيود مفروضة بناءا على معلومات مسبقة للنظرية الإقتصادية، يمكننا إعادة البناء النظري للنموذج في شكل يتماشى و هذه القيود. أما إذا كانت ناتجة عن مشاكل في التصرف الإحصائي للنموذج المدروس، فإن تلك القيود ليست بالضرورة دائما صحيحة.

على العموم تتمثل هذه الطريقة في إدخال مجموعة من القيود الخطية و الصحيحة على معالم النموذج من أجل إختبار بعض الفرضيات المطلوبة من طرف النظرية الإقتصادية أو من طرف الإحصائيين. و تكون هذه القيود الخطية مفروضة لإختبار صحتها إحصائيا أو ميدانيا، فإذا فرضنا أن هناك  $m < k$  من القيود الخطية، يمكننا تمثيلها تحت الفرضية  $H_0$  كما يلي:

$$H_0: R\beta = r$$

$$H_A: R\beta \neq r$$

حيث أن  $R$  هي  $m \times k$  مصفوفة قيود و ذات رتبة  $m$ .  $r$  هو موجه عمود للقيود  $m \times 1$ . فمثلا إذا كان النموذج:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$

و كانت مجموعة القيود الخطية المطلوب إختبارها تحت الفرضية  $H_0$  هي:



$$\beta_1 + \beta_2 = 3$$

$$\beta_2 - \beta_3 + \beta_k = 0 \quad \dots\dots\dots(3.55)$$

فيمكن صياغتها على الشكل التالي:  $R\beta = r$ ، أي أن:

$$\begin{bmatrix} 1 & 1 & 0 & \dots & \dots & \dots & 0 \\ 0 & 1 & -1 & 0 & \dots & 0 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \vdots \\ \vdots \\ \vdots \\ \vdots \\ \vdots \\ \beta_k \end{bmatrix} = \begin{pmatrix} 3 \\ 0 \end{pmatrix}$$

أما إذا أردنا إختبار المعالم الفردية للنموذج مثل:

$$H_0: \beta_j = 0 \quad j = 1, 2, \dots, k \dots\dots\dots(3.56)$$

$$H_A: \beta_j \neq 0$$

فإننا نكتب:

$$R \quad \beta = r$$

$$\begin{bmatrix} 0 & \dots & \dots & 1 & 0 & \dots & 0 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \vdots \\ \vdots \\ \vdots \\ \beta_j \\ \vdots \\ \beta_k \end{bmatrix} = 0$$

و إذا طلب منا إختبار الفرضية المجموعة و الخاصة بكل أميال الإنحدار فنكتب:

$$H_0: \beta_2 = \beta_3 = \dots = \beta_k = 0 \quad \dots\dots\dots (3.57)$$

$$H_A: \beta_j \neq 0$$

على الأقل

و تكون هذه القيود على الشكل:

$$\begin{bmatrix} 0 & 1 & 0 & \dots & \dots & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & 0 & & & \vdots \\ \vdots & & \vdots & & & 0 \\ 0 & \dots & \dots & \dots & 0 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \vdots \\ \vdots \\ \vdots \\ \vdots \\ \beta_k \end{bmatrix} = \begin{bmatrix} 0 \\ \vdots \\ \vdots \\ \vdots \\ \vdots \\ 0 \end{bmatrix}$$

$$R \quad \beta = r$$

$$(k-1) \times k \quad k \times 1 \quad (k-1) \times 1$$

أي أن كل المتغيرات المستقلة  $(X_2, X_3, \dots, X_k)$  لا تؤثر في تحديد المتغير التابع  $Y$ . إذا اعتبرنا مجموعة القيود الخطية  $R\beta = r$  هي معادلة خطية، حيث أن الموجه العمود  $r$  يكون معروفاً و كذلك قيم مصفوفة القيود  $R$  معلومة. لنعوض موجه المعالم  $\beta$  بمقدر المربعات الصغرى العادية  $\hat{\beta}$ ، ثم نلاحظ أن:

$$E(R\hat{\beta}) = RE(\hat{\beta}) = R\beta \dots\dots\dots (3.58)$$

لكن في ظل الفرضية  $H_0$  نعرف أن  $R\beta = r$  و يكون التباين:

$$\text{var}(R\hat{\beta}) = R \text{var}(\hat{\beta}) R' = \sigma_u^2 R(X'X)^{-1} R' \dots\dots\dots (3.59)$$

و ما دام  $\hat{\beta}$  يتبع التوزيع الطبيعي المتعدد، فإن تركيبته الخطية تكون كذلك أي:

$$R\hat{\beta} \sim N(R\beta, \sigma_u^2 R(X'X)^{-1} R')$$

كما أنه من خاصية عدم التحيز  $E(R\hat{\beta}) - R\beta = 0$  ينتج لدينا:

$$R\hat{\beta} - R\beta = R(\hat{\beta} - \beta) = RAU \dots (3.60)$$

و ذلك بإستعمال المعادلة  $\hat{\beta} = \beta + AU$  لتصبح لدينا:

$$R(\hat{\beta} - \beta) = RAU \sim N(0, \sigma_u^2 RAA'R')$$

و هي كذلك تحت  $H_0$  صحيحة:

$$R(\hat{\beta} - \beta) = R\hat{\beta} - r \sim N(0, \sigma_u^2 RAA'R') \dots (3.61)$$

و منه نقول إن كان لدينا موجه المتغيرات العشوائية  $Z$  ذي الأبعاد  $n \times 1$

بحيث يحقق  $Z \sim N(0, P_{n \times n})$  ، فإن  $Z'P^{-1}Z \sim \chi_n^2$  ، و إذا طبقنا ذلك

على المعادلة (61.3) نجد:

$$(R\hat{\beta} - r)' [\sigma_u^2 RAA'R']^{-1} (R\hat{\beta} - r) \sim \chi_m^2 \dots (3.62)$$

حيث  $m$  هي عدد القيود و تمثل كذلك رتبة المصفوفة  $RAA'R'$  . إن

المشكل مع المعادلة (62.3) هو عدم معرفتنا  $\sigma_u^2$  حتى نجري الاختبار المطلوب

أعلاه. لكننا نعرف مقدار هذه القيمة و هو  $\hat{\sigma}_u^2$  مثلما وجدنا في المعادلة (39.3).

لدينا:

$$\frac{RSS}{\sigma_u^2} = \frac{(n-k)\hat{\sigma}_u^2}{\sigma_u^2} \sim \chi_{n-k}^2$$

تكون هذه القيمة مستقلة عن مقدار المربعات الصغرى  $\hat{\beta}$  ، كما بينا من

قبل، وفي نفس الوقت مستقلة عن تركيبته الخطية  $R\hat{\beta}$  . حيث إذا كانت لدينا

صيغتين تربيعيتين  $z'Dz$  ،  $z'Mz$  و كانت

$$z \sim N(0, I) \dots (3.63)$$

ثم إن  $D$  ،  $M$  مصفوفتان متناظرتان و خاملتان. نقول عن الصيغتين التربيعيتين

$z'Dz$  ،  $z'Mz$  بأنهما مستقلتين عن بعضهما البعض إذا و فقط إذا كانت:



$$D.M(7)=0.....(3.64)'$$

إن تكوين إختبار التوزيع F يكون في هذه الحالة:

$$\frac{\chi_m^2/m}{\chi_{n-k}^2/(n-k)} = \frac{(R\hat{\beta}-r)' [RAA'R']^{-1} (R\hat{\beta}-r)/m}{RSS/(n-k)}$$

$$= \frac{(R\hat{\beta}-r)' [RAA'R']^{-1} (R\hat{\beta}-r) \cdot m}{\hat{\sigma}_u^2} \sim F_{m, n-k} .....(3.64)''$$

و يكون الإختبار على الشكل:

$$R\hat{\beta} \neq r \text{ أي أن } H_0 \text{ نرفض الفرضية } F_{m, n-k} > F_{m, n-k, \lambda\%}$$

$$R\hat{\beta} = r \text{ أي أن } H_0 \text{ نقبل الفرضية } F_{m, n-k} \leq F_{m, n-k, \lambda\%}$$

فإذا أردنا إختبار الفرضية الموجودة بالمعادلة (56.3) تكون R عبارة

عن موجه سطر أي:

$$R = [0 \quad \dots \quad \dots \quad 0 \quad 1 \quad 0 \quad \dots \quad 0]$$

أما r فهي عدد سلمي r = 0 في هذه الحالة وتكون:  $\beta_j = 0$  لتصبح:

$$R \hat{\beta} = r$$

$$[0 \quad \dots \quad \dots \quad 0 \quad 1 \quad 0 \quad \dots \quad 0] \begin{bmatrix} \hat{\beta} \\ \vdots \\ \hat{\beta}_j \\ \vdots \\ \hat{\beta}_K \end{bmatrix} = 0$$

$$R\hat{\beta} - r = \hat{\beta}_j .....(3.64)''' \quad \text{و ينتج أن:}$$

نترك إثبات هذه النظرية للفصل الرابع عند تطرقنا لتقدير القيود الخطية.

لأن  $m = 1$  و منه فإن:

$$\text{var}(R\hat{\beta} - r) = \sigma_u^2 R A A' R' = \sigma_u^2 R (X'X)^{-1} R'$$

و ما دام  $R$  أصبحت عبارة عن موجه أصفار  $(1 \times k)$  ما عدا العنصر  $(j)$  الذي هو الواحد، فإن النتيجة أعلاه تصبح:

$$\text{var}(R\hat{\beta} - r) = \sigma_u^2 (X'X)^{-1} = \sigma_u^2 a_{jj}^{(8)} \dots \dots \dots (3.65)$$

و ذلك بناءا على الملاحظة (64.3). ليكون الإختبار على الشكل:

$$F = \frac{(R\hat{\beta} - r)' [\sigma_u^2 R (X'X)^{-1} R']^{-1} (R\hat{\beta} - r) / m}{\hat{\sigma}_u^2 / \sigma_u^2} = \frac{\hat{\beta}_j (\sigma_u^2 a_{jj})^{-1} \hat{\beta}_j / 1}{\hat{\sigma}_u^2 / \sigma_u^2}$$

$$= \frac{\hat{\beta}_j^2}{\hat{\sigma}_u^2 a_{jj}} = \left( \frac{\hat{\beta}_j}{\hat{\sigma}_u \sqrt{a_{jj}}} \right)^2 \sim t_{n-k}^2 \sim F_{1, n-k} \dots \dots \dots (3.66)$$

و كما لاحظنا في الفصل الثاني من المعادلة (53.2) عند إيجاد العلاقة ما بين التوزيعين  $F$  و  $t$  هي:

$$t_{n-k}^2 = F_{1, n-k} \dots \dots \dots (3.67)$$

أما إذا أردنا إختبار الفرضية الموجودة بالمعادلة (57.3) فيكون الموجه الخاص بالقيود:

8

$$R(X'X)^{-1}R' = \begin{bmatrix} 0 & \dots & 1 & \dots & 0 \end{bmatrix} \begin{bmatrix} a_{11} & \dots & \dots & \dots & a_{1k} \\ \vdots & & & & \vdots \\ \vdots & & a_{jj} & & \vdots \\ \vdots & & & & \vdots \\ a_{k1} & & & & a_{kk} \end{bmatrix} \begin{bmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix} = a_{jj}$$

ت  $a_{jj}$  هي عناصر القطر  $j$  للمصفوفة  $(X'X)^{-1}$ .

$$R\hat{\beta} - r = \begin{bmatrix} \hat{\beta}_2 \\ \hat{\beta}_3 \\ \vdots \\ \hat{\beta}_k \end{bmatrix} \quad \dots (3.68)$$

و إذا كتبنا المعادلة (68.3) على الشكل:

$$\hat{\beta}_0 = [\hat{\beta}_2 \quad \hat{\beta}_3 \quad \dots \quad \hat{\beta}_k]$$

المصفوفة  $X$  إلى  $X = [i: X_0]$  حيث أن كل من  $X_0, \hat{\beta}_0, i$  معرفة بالمعادلات (45.3) و (41.3) على الترتيب، لتكون المصفوفة  $X'X$  على الشكل:

$$X'X = \begin{bmatrix} n & i'X_0 \\ X_0'i & X_0'X_0 \end{bmatrix} \dots (3.69)$$

و بتطبيق قانون مقلوب (معكوس) المصفوفة المجزأة، للمصفوفة  $(X'X)^{-1}$  يكون الجزء المقابل لـ  $X_0'X_0$  هو:

$$\left( X_0'X_0 - X_0' \frac{ii'}{n} X_0 \right)^{-1} = (X_0'M_0X_0)^{-1} = R(X'X)^{-1}R'$$

و بتطبيق المعادلة (64.3) على هذه الحالة نجد:

$$\frac{\hat{\beta}_0'(X_0'M_0X_0)\hat{\beta}_0/(k-1)}{\hat{\sigma}_u^2} \sim F_{k-1, n-k} \dots (3.70)$$

ومن المعادلة (70.3) نلاحظ أن  $\hat{\sigma}_u^2 = RSS/(n-k)$

$$ESS = \hat{\beta}_0'X_0'M_0X_0\hat{\beta}_0 \quad \text{و كذلك}$$

لتصبح:



$$\frac{ESS/(k-1)}{RSS/(n-k)} \sim F_{k-1, n-k} \dots\dots (3.71)$$

و بالتعويض عن قيمة  $R^2$  الموجودة بالمعادلة (40.2) من الفصل الثاني نجد:

$$\frac{R^2/(k-1)}{(1-R^2)/(n-k)} \sim F_{k-1, n-k} \dots\dots (3.72)$$

و اعتمادا على تعريف  $\bar{R}^2$  بالمعادلة (24.3) يكون:

$$\frac{(n-1) - (1-\bar{R}^2)(n-k)}{(1-\bar{R}^2)(k-1)} \sim F_{k-1, n-k} \dots\dots (3.72)$$

### 6-3 الإنحدار المجزأ Partitioned regression

تكلما بالمعادلة (13.3)، عن معالم الإنحدار الجزئي، حيث تجري العملية

بواسطة إجراء إنحدار نموذجين مختلفين، في المعادلة:

$$Y = X\beta + Z\gamma + U \dots\dots\dots (3.73)$$

إذا أردنا تحويل أثر مصفوفة المتغيرات  $Z$  إلى المصفوفة  $X$  نقوم

بتحدير  $X$  في  $Z$  وذلك لقياس أثر  $X$  في  $Y$  مع ثبات مصفوفة المتغيرات

$$X = Z\delta + U \quad \text{المستقلة } Z \text{ كما يلي:}$$

و بتطبيق قانون المربعات الصغرى العادية نجد أن:

$$\hat{X} = Z\hat{\delta}$$

$$X = Z\hat{\delta} + \hat{U}$$

$$\hat{\delta} = (Z'Z)^{-1}Z'X$$

و منه فإن البواقي تصبح:

$$\hat{U} = X - Z\hat{\delta} = [I - Z(Z'Z)^{-1}Z']X = M_Z X \dots\dots (3.74)$$

حيث أن  $M_Z = I - Z(Z'Z)^{-1}Z'$  هي مصفوفة متناظرة وخاملة. وفي مرحلة ثانية نحدر  $Y$  على البواقي  $\hat{U}$  لنبين أثر  $X$  المعدلة في  $Y$  كما يلي:

$$Y = \hat{U}\theta + V \dots\dots(3.75)$$

ليكون موجه المقدرات  $\hat{\theta}$  كمايلي:

$$\hat{\theta} = (\hat{U}'\hat{U})^{-1}\hat{U}'Y = (X'M_ZX)^{-1}X'M_ZY \dots\dots(3.76)$$

لنعود الآن إلى المعادلة (73.3) ونقدرها مباشرة. حيث نكتب:

$$Y = (X:Z) \begin{pmatrix} \beta \\ \dots \\ \gamma \end{pmatrix} + U = X^*\beta^* + U \dots\dots(3.77)$$

حيث أن:  $\beta^* = (\beta:\gamma)'$ ،  $X^* = (X:Z)$

إن تطبيق قانون المربعات الصغرى العادية على المعادلة (77.3) يعطي

$$X^{*'}Y = X^{*'}X^*\hat{\beta}^* \quad \text{المعادلات الطبيعية:}$$

وبالتعويض عن قيم  $X^*$ ،  $\beta^*$  أعلاه نجد:

$$X'Y = X'X\hat{\beta} + X'Z\hat{\gamma}$$

$$Z'Y = Z'X\hat{\beta} + Z'Z\hat{\gamma}$$

و من المعادلات الطبيعية الثانية نجد:

$$Z'(Y - X\hat{\beta}) = Z'Z\hat{\gamma}$$

$$\hat{\gamma} = (Z'Z)^{-1}Z'(Y - X\hat{\beta}) \dots\dots(3.78)$$

و بتعويض قيمة  $\hat{\gamma}$  بالمعادلات الطبيعية الأولى نجد:

$$X'Y = X'X\hat{\beta} + X'Z(Z'Z)^{-1}Z'Y - X'Z(Z'Z)^{-1}Z'X\hat{\beta}$$

$$X'Y - X'Z(Z'Z)^{-1}Z'Y = X'X\hat{\beta} - X'Z(Z'Z)^{-1}Z'X\hat{\beta}$$

$$X'M_Z Y = X'M_Z X\hat{\beta}$$

$$\hat{\beta} = (X'M_Z X)^{-1} X'M_Z Y = \hat{\theta} \dots \dots (3.79)$$

و منه نقول إذا نزعنا أثر  $Z$  من  $Y$  و  $X$  عن طريق تحديد هذه الأخيرة في  $Z$  لناخذ بواقى الإتحاد. ثم نحدر  $Y$  في هذه البواقى سوف نحصل على النتيجة المحصلة من تحديد  $Y$  في  $Z$  و  $X$  مباشرة. و تصلح هذه الطريقة لإزالة أثر الزمن في السلاسل الزمنية أو التمهيد<sup>(9)</sup> Detrending.

### 7-3 مثال (2.3):

لدينا بيانات عن الإستهلاك و الدخل الفرديين بالأسعار الحقيقية للفترة (67-89) للجزائر من سلسلة تمارين الفصل الثاني، و إذا كان الشكل الدالي على النحو:  $C_t = \beta_1 + \beta_2 \Delta Y_t + \beta_3 C_{t-1} + \beta_4 Y_{t-1} + u_t$  حيث أن  $\Delta Y_t = Y_t - Y_{t-1}$  وهي الدالة المقترحة من طرف Houthakker-Taylor 1970 و حصلنا على المعادلة التقديرية التالية:

$$C_t = -86,76 + 0,767 \Delta Y_t + 0,45 C_{t-1} + 0,51 Y_{t-1}$$

$$S - T \quad (0,467)^* \quad (4,79) \quad (1,817)^* \quad (2,098)$$

حيث أن  $S - T$  هي الإحصاءة  $t$ ، و \* تعني أن المقدّر غير مقبول إحصائيا.

<sup>9</sup>- M.B. Stewart and K.F. Walis "Introductory Econometrics" Basil Black Well-Oxford: Page 160. England 1981.



$$R^2 = 0,98 \text{ , } \bar{R}^2 = 0,97 \text{ , } h = 4,63 \text{ , } F(3,18) = 272,51$$

$$RSS = 354028,8 \text{ , } n = 22$$

الملاحظة الأولى المستقاة من المعادلة التقديرية أعلاه هي أن الميل الحدي للإستهلاك (0,51) ضعيف جدا وهذا بسبب وجود المتغير التابع المؤخر  $C_{t-1}$  والممثل لإستهلاك السنة الماضية، لكن نجد أن هذه القيمة تكون مرتفعة بالنسبة للمدى الطويل حيث تساوي (0,927). وهذا يعني فعالية و تصرف أحسن للنموذج على المدى البعيد. و إذا أردنا هنا إختبار الفرضية القائلة بأن:

$$H_0: \beta_2 = \beta_3 = \beta_4 = 0$$

ضد الفرضية البديلة والقائلة:

$$H_A: \beta_2 \neq 0 \text{ ، أو } \beta_3 \neq 0 \text{ ، أو } \beta_4 \neq 0$$

$$\text{أو } (\beta_3, \beta_4) \neq 0 \text{ ، أو } (\beta_3, \beta_2) \neq 0$$

$$\text{أو } (\beta_2, \beta_4) \neq 0 \text{ ، أو } (\beta_2, \beta_3, \beta_4) \neq 0$$

فيكون الإختبار هو:

$$F = \frac{R^2 / (k - 1)}{(1 - R^2) / (n - k)} = 272,51 \sim F_{3,18}$$

أما قيمة F المجدولة فهي  $F_{3,18,5\%} = 3,16$ .

و منه نلاحظ أن القيمة المحسوبة أكبر من تلك المجدولة لنرفض في الأخير  $H_0$  و نقبل معنوية النموذج ككل. أما بالنسبة للمعالم الفردية فنجد:

$$H_0: \beta_j = 0 \text{ vs } H_A: \beta_j \neq 0$$

$$\frac{\hat{\beta}_j}{SE(\hat{\beta}_j)} = t_{n-k} \text{ , } j = 1, 2, 3, 4 \text{ , } t_{18,0,025} = 2,101$$

$$\frac{\hat{\beta}_1}{SE(\hat{\beta}_1)} = 0,467 \rightarrow H_0 \text{ نقبل}$$

$$\frac{\hat{\beta}_2}{SE(\hat{\beta}_2)} = 4,79 \rightarrow H_0 \text{ نرفض}$$

$$\frac{\hat{\beta}_3}{SE(\hat{\beta}_3)} = 1,817 \rightarrow H_0 \text{ نقبل}$$

$$\frac{\hat{\beta}_4}{SE(\hat{\beta}_4)} = 2,098 \rightarrow H_0 \text{ نقبل}$$

و منه نلاحظ بأن المعنوية الإحصائية لأغلبية المعالم الفردية غير مقبولة (ماعدا  $\beta_2$ ). أما بالنسبة لمجموعة أميال الإتحدار فكانت فرضية العدم مرفوضة. لكن هذا ليس معناه أن النموذج جيد إحصائيا رغم أن معامل التحديد يبين بأن 98% من تغيرات الإستهلاك مشروحة بواسطة خط الإتحدار. حيث إذا أردنا معرفة قيمة التغيرات المشروحة و التغيرات الكلية نجد:

$$TSS = ESS + RSS$$

$$1 - R^2 = RSS/TSS \Rightarrow TSS = RSS/(1 - R^2) = 17701440$$

$$ESS = TSS - RSS = 17347412$$

كما أن قبول الإختبار  $F$  للفرضية البديلة  $H_A$  و رفض المعالم الفردية بواسطة التوزيع  $t$  يعني أن هناك مشكل تعدد خطي و الذي نناقشه لاحقا بالفصل

الرابع. أما إذا أردنا إختبار الفرضية القائلة بأن:  $H_0: \beta_2 = 1$

$$t_{18} = \frac{\hat{\beta}_2 - 1}{SE(\hat{\beta}_2)} = |-1,456| = 1,456 \quad \text{فإن:}$$

وهي قيمة أقل من تلك المجدولة. وهذا معناه أننا نقبل  $H_0$ .

### 8-3 سلسلة تمارين حول الفصل الثالث:

#### التمرين الأول:

في النموذج الخطي التالي:  $Y_i = \beta_1 + \sum_{j=2}^6 \beta_j X_{ji} + u_i$

(a) وضح كيف يمكن اشتقاق قانون التوزيع F للفرضية  $\beta_4 = \beta_5 = \beta_6 = 0$ .

(b) إذا كان  $\hat{\beta}$  هو مقدار المربعات الصغرى للموجه  $\beta$ ، و  $b$  هو موجه آخر لمقدرات خطية غير متحيزة. بينما  $W$  هو موجه الثوابت، بين بأن:

$$\text{var}(b_i) \geq \text{var}(\hat{\beta}_i) \text{ وبالتالي فإن: } \text{var}(W'b) \geq \text{var}(W'\hat{\beta})$$

(c) متى يكون  $R^2$  معدوماً أو بأكبر قيمة ممكنة؟ وهل فعلاً  $0 \leq \bar{R}^2 \leq 1$  ؟

(d) إذا كانت لدينا القيود التالية:

$$\beta_1 + \beta_2 - 2\beta_4 = 0, \quad \beta_3 + 5\beta_5 = 0, \quad \beta_2 + \beta_4 - \beta_6 = 0$$

فأكتبها على الشكل:  $R\beta = r$

(e) إذا أصبح النموذج أعلاه على الشكل:  $Y_i = \beta_1 + \sum_{j=2}^3 \beta_j X_{ji} + u_i$ ، فأوجد

مقدرات المربعات الصغرى لمعالم النموذج الجديد عندما تكون  $\beta_2 + \beta_3 = 1$ .

ثم أشتق قانون الاختبار المناسب لهذه الحالة. و اختبر كذلك الفرضية:

$$H_0: \beta_2 + \beta_3 = 0$$



## التمرين الثاني:

لنعتبر النموذجين التاليين:

$$I: \log Y_i = \beta_1 + \beta_2 \log X_{2i} + \beta_3 X_{3i} + u_i$$

$$II: \log(Y_i/X_{2i}) = \alpha_1 + \alpha_2 \log X_{2i} + \alpha_3 X_{3i} + u_i$$

(a) بين بأن تطبيق قانون المربعات الصغرى العادية على النموذجين أعلاه يعطي

$$\hat{\alpha}_2 - \hat{\beta}_2 = 1, \quad \hat{\alpha}_3 = \hat{\beta}_3, \quad \hat{\alpha}_1 = \hat{\beta}_1$$

(b) بين بأن بواقي الإنحدار من النموذجين متماثلة.

(c) تحت أية شروط تكون قيمة  $R^2$  المحصلة من النموذج I تزيد عن تلك المحصلة من النموذج II. و ماذا تخبرنا عن جودة التوفيق ؟

## التمرين الثالث:

تعطى البيانات التالية لقيم الإنفاق على الملابس  $Y$ ، الإنفاق الكلي  $X_2$ ،

وسعر الملابس  $X_3$ .

$$X'X = \begin{bmatrix} 10 & 523 & 705 \\ - & 33439 & 2667,5 \\ - & - & 689,25 \end{bmatrix}, \quad X'Y = \begin{bmatrix} 78,8 \\ 4896,5 \\ 429,9 \end{bmatrix}$$

$$Y'Y = 143216 \quad n = 10$$

(a) كون المصفوفة  $(X'X)^{-1}$

(b) أوجد الموجه  $\hat{\beta}$

(c) أحسب  $R^2$ ،  $\bar{R}^2$ ،  $SE(\hat{\beta}_j)$  حيث  $j = 1, 2, 3$ . وكون إختبارات المعنوية لها.

(d) كون 95 % مجالات ثقة لمعالم المجتمع.

(e) أوجد التغيرات المشروحة وغير المشروحة والتغيرات الكلية.

(f) اشرح المعنى الإقتصادي للنموذج.

$$Y = [i: X_0] \begin{bmatrix} \beta_1 \\ \dots \\ \beta_0 \end{bmatrix} \quad (g) \text{ لنكتب نموذج العلاقة أعلاه على الشكل:}$$

ونعرف:  $M_0 = I - i(i'i)^{-1}i'$ ، حيث أن:

$$i' = (1, \dots, 1), \quad X_0^* = \begin{bmatrix} X_2 & X_3 \end{bmatrix}, \quad \beta_0' = \begin{bmatrix} \beta_2 & \beta_3 \end{bmatrix}$$

إختبر الفرضية  $R\beta_0 = 0$  مستعملا نسبة التوزيع  $F$ .

#### التمرين الرابع:

لديك نموذج الإنفاق الإستهلاكي للأفراد الجزائريين خلال الفترة 1967-

$$1989 \text{ بالأسعار الحقيقية. } C_t = \beta_1 + \beta_2 Y_t + \beta_3 C_{t-1} + \beta_4 Y_{t-1} + u_t$$

حيث أن  $C_t$  هي الإستهلاك الفردي السنوي،  $Y_t$  الدخل الفردي السنوي.

و بعد إستعمال قانون المربعات الصغرى العادية لعينة الملاحظات حصلنا على

الإنحدارين التاليين:

$$I: \hat{C}_t = -98,36 + 0,83 Y_t + 0,43 C_{t-1} - 0,29 Y_{t-1}$$

$$S.E \quad (179,55) \quad (0,08) \quad (0,24) \quad (0,2)$$

$$R^2 = 0,98, \quad \bar{R}^2 = 0,97, \quad RSS = 357690,8, \quad F_{3,19} = 326,43$$

$$II: \hat{C}_t = -343,15 + 0,96 Y_t$$

$$S.E (140,5) (0,032)$$

$$R^2 = 0,976, \quad \bar{R}^2 = 0,975, \quad RSS = 436351,1, \quad F_{1,21} = 883,49$$

- (a) أوجد قيمة مقدار تباين الخطأ من النموذجين أعلاه.
- (b) من النموذجين أعلاه كـون الاختبار الإحصائي المناسب للفرضية  $H_0: \beta_3 = \beta_4 = 0$ .
- (c) من النموذج الثاني إختبر الفرضية  $H_0: \beta_2 = 1$  وكون مجال ثقتها لما  $\lambda = 0,05$ .
- (d) بناءا على معلوماتك من النظرية الإقتصادية و الإحصائية، أي النموذجين تفضل؟ ولماذا؟

#### التمرين الخامس:

لتكن دالة الإنتاج من نوع كوب-دو غلاس لدولة ما على الشكل:

$$Q_t = AL_t^\alpha \cdot K_t^\beta \cdot e^{u_t}$$

و بعد إدخال اللوغاريتم الطبيعي على الدالة و تطبيق قانون المربعات الصغرى على عينة الملاحظات ( $n = 39$ )، حصلنا على النموذج التقديري التالي:

$$\hat{Y}_t = -3,8766 + 1,4106 X_{2t} + 0,4162 X_{3t}$$

$$S.E (0,255) (0,0884) (0,0505)$$

$$R^2 = 0,9937, \quad \hat{\sigma}_u = 0,03755$$

حيث أن:  $X_{3t} = \log K_t$ ,  $X_{2t} = \log L_t$ ,  $C = \log A$



- (a) إختبر المعالم الفردية للإتحاد وأشرح معناها الإحصائي.
- (b) بين دور  $R^2$  و  $\bar{R}^2$  وأحسب  $\bar{R}^2$ .
- (c) إختبر الفرضية  $H_0: \alpha = \beta = 0$  مستعملا  $R^2$  و درجات الحرية فقط.
- (d) هل تتعارض نتائجك في (a) مع تلك المحصلة في (c) ؟ لماذا؟
- (e) أوجد RSS
- (f) إذا كانت  $(X'X)^{-1} = \begin{bmatrix} 5,55 & -3 \\ -3 & 1,8 \end{bmatrix}$ ، أوجد  $\text{var}(\hat{\alpha})$ ،  $\text{var}(\hat{\beta})$ .
- (g) إشرح المعني الإقتصادي لكل من  $\hat{\alpha}$ ،  $\hat{\beta}$ .

#### التمرين السادس:

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$$

ليكن النموذج التالي:

$$i = 1, 2, \dots, 10$$

مع المعطيات:

$$(X'X) = \begin{bmatrix} 3 & 1 & -2 \\ 1 & 2 & 1 \\ -2 & 1 & 4 \end{bmatrix}, \quad X'Y = \begin{bmatrix} 1 \\ 7 \\ 9 \end{bmatrix}$$

- (a) أوجد موجه المقدرات  $\hat{\beta}$
- (b) إذا كانت  $\sum Y_i = 5$ ،  $Y'Y = 58$ ، أوجد  $\bar{R}^2$ ،  $R^2$ ، RSS، ESS.
- (c) كون مجالات الثقة  $\lambda = 0,05$ .
- (d) إذا كانت في العلاقة أعلاه  $\beta_1 = 0$ ، فأعد تقدير الموجه  $\beta$  من جديد، و أحسب المقادير:  $\hat{\sigma}_u^2$ ،  $\bar{R}^2$ ،  $R^2$ ، ESS، RSS.

#### التمرين السابع:

لديك النموذج الخطي العام  $Y = X\beta + U$  مع المعطيات:

$$X'X = \begin{bmatrix} 10 & 80 & 300 \\ - & 890 & 2400 \\ - & - & 9200 \end{bmatrix}, \quad X'Y = \begin{bmatrix} 1200 \\ 1010 \\ 3620 \end{bmatrix}, \quad Y'Y = 1537$$

(a) أوجد موجه المقدرات  $\hat{\beta}$ ,  $\hat{\sigma}_u^2$ ,  $R^2$ ,  $\bar{R}^2$ ,  $RSS$ ,  $ESS$ .

(b) إختبر الفرضيات:  $\lambda = 0,05$

$$H_{01}: \beta_2 = 0 \quad \text{vs} \quad H_{A1}: \beta_2 > 0$$

$$H_{02}: \beta_3 = 1 \quad \text{vs} \quad H_{A2}: \beta_3 > 1$$

$$H_{03}: \beta_2 = \beta_3 = 0 \quad \text{vs} \quad H_{A1}: \beta_2 \neq 0, \text{ أو } \beta_3 \neq 0, \text{ أو } (\beta_2, \beta_3) \neq 0$$

التمرين الثامن:

لديك النموذج الخطي التالي:  $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$

و نكتبه على الشكل:

$$Y = i\beta_1 + X_0\beta_0 + U$$

$$M_0 = I - i(i'i)^{-1}i'$$

و كانت لدينا المعلومات التالية:

$$X_0'M_0X_0 = \begin{bmatrix} 20 & 30 \\ 30 & 50 \end{bmatrix}, \quad Y'M_0X_0 = (3 \quad 7),$$

$$Y'M_0Y = 2, \quad n = 10$$

(a) قدر أميال الإنحدار.

(b) أحسب  $\hat{\sigma}_u^2$ ,  $R^2$ ,  $RSS$ ,  $ESS$ ,  $\hat{\beta}_0$ .

## الفصل الرابع: مبادئ تطبيق الإنحدار المتعدد

### 1-4 إضافة متغيرات للإنحدار:

عند تطرقنا لحساب معامل التحديد المضاعف وبالتالي توسيع نموذج الإنحدار إلى عدة متغيرات مستقلة (بالفصل الثالث)، تبين لنا بأن إضافة متغيرات (محدرات) جديدة للنموذج سوف تقلل من قيمة  $RSS$  وتزيد من قيمة  $ESS$ . أما مجموع مربعات الانحرافات الكلية  $TSS$  فتبقى ثابتة. وبناءً على تعريف  $R^2$  في المعادلة (22.3) بالفصل الثالث نلاحظ أن قيمته تزداد كذلك بغض النظر عن أهمية المتغير المستقل المضاف لمعادلة الإنحدار. ومنه لجأنا إلى معامل التحديد المضاعف والمصحح (المعدل) بواسطة درجات الحرية  $\bar{R}^2$ .

نبحث الآن في هذه الفقرة عما يحدث لمقدرات المربعات الصغرى لما نضيف موجهها لمحدرات جديدة محصلة من تحديد موجه المتغيرات التابع  $Y$  في مصفوفة المتغيرات المستقلة  $X$ . ولنعبر النموذجين البديلين:

$$Y = X\beta + U \dots (4.1)$$

$$Y = X\beta + Z\gamma + U \dots (4.2)$$

حيث أن  $X$  هي  $n \times (k - m)$ ، و  $Z$  هي  $n \times m$  مصفوفتي متغيرات مستقلة. كما أن  $\beta$  هي  $(k - m) \times 1$ ، و  $\gamma$  هي  $m \times 1$  موجهي معالم. ولنجري قانون المربعات الصغرى على النموذجين لنجد المعادلتين التقديريتين:

$$Y = X\hat{\beta} + \hat{U} \dots (4.3)$$

$$Y = Xb + Z\tau + e \dots (4.4)$$

حيث أن  $\tau$  هي موجه مقدرات المربعات الصغرى لـ  $\gamma$ ، و  $b$  موجه مقدرات لـ  $\beta$  من المعادلة (2.4).



وواضح أن إحدار الموجه  $Y$  في المصفوفتين  $X$  و  $Z$  لا يعطي نفس مقدار  $\beta$ ، ونفس البواقي  $\hat{U}$  في الإحدار العادي للمعادلة (1.4) (أي إحدار  $Y$  في  $X$  لوحدها). وسنوضح ذلك بشكل موسع لدى تطرقنا للنتائج الإحصائية. حيث نلاحظ أن إحدار  $Y$  في  $X$  يعطي النتيجة:

$$X'\hat{U} = 0^{(1)} \dots (4.5)$$

بينما من إحدار المعادلة (2.4) نحصل على الخاصيتين:

$$X'e = 0 \dots (4.6)$$

$$Z'e = 0 \dots (4.7)$$

فإحدار  $Y$  في  $X$  من المعادلة (1.4)، يعطي، من تطبيق المربعات الصغرى موجه المقدرات التالي:

$$\hat{\beta} = (X'X)^{-1} X'Y \dots (4.8)$$

وكذلك موجه البواقي:

$$\hat{U} = Y - X\hat{\beta} = M_X Y = M_X U \dots (4.9)$$

حيث أن:

$$M_X = I - X(X'X)^{-1} X' \dots (4.10)$$

وهي مصفوفة متناظرة وخاملة.

أما من إحدار  $Y$  في كل من  $X$  و  $Z$  بالمعادلة (2.4)، إذا أعدنا صياغة هذه الأخيرة على الشكل:

$$Y = \begin{pmatrix} X & : & Z \end{pmatrix} \begin{pmatrix} \beta \\ \dots \\ \gamma \end{pmatrix} + U = Z_0 \gamma_0 + U \dots (4.11)$$

فبتطبيق المربعات الصغرى على (11.4) نحصل على موجه المقدرات  $\hat{\gamma}_0$  والمحتوى على كل من  $\tau$  و  $b$  كما يلي:

1- من خصائص المربعات الصغرى المذكورة بالفصلين الثاني والثالث.

$$\hat{\gamma}_0 = (Z'_0 Z_0)^{-1} Z'_0 Y$$

$$\begin{pmatrix} b \\ \tau \end{pmatrix} = \begin{bmatrix} X'X & X'Z \\ Z'X & Z'Z \end{bmatrix}^{-1} \begin{pmatrix} X'Y \\ Z'Y \end{pmatrix}$$

وللحصول على موجهي المقدرات  $b$ ،  $\tau$ ، يمكن أن نستعمل قانون مقلوب المصفوفات المعمم Matrix General Inverse، أو لنضرب المعادلة (4.4) بالمصفوفة  $Z'$  لنجد:

$$Z'Y = Z'Xb + Z'Z\tau + Z'e$$

$$Z'Y = Z'Xb + Z'Z\tau \quad \text{وباستعمال (7.4) نجد:}$$

$$\tau = (Z'Z)^{-1} Z'(Y - Xb) \quad \text{وإذا كانت } Z'Z \text{ غير شاذة فإن:}$$

ولكن هذه العبارة تحل  $\tau$  بدلالة  $b$  غير المعروفة بدورها. ويكون الحل الكامل لمقدر  $\gamma$  بضرب المعادلة (4.4) بالمصفوفة المتناظرة والخاملة  $M_X$  لنجد:

$$M_X Y = M_X Z\tau + e \dots (4.12)$$

$$M_X e = e, \quad M_X X = 0 \quad \text{حيث أن:}$$

ثم نضرب المعادلة (12.4) بالمصفوفة  $Z'$  لنجد:

$$Z'M_X Y = Z'M_X Z\tau + Z'e = Z'M_X Z\tau \dots (4.13)$$

وإذا كانت الصيغة التربيعية  $Z'M_X Z$  غير شاذة فنحصل على:

$$\tau = (Z'M_X Z)^{-1} Z'M_X Y \dots (4.14)$$

وللحل من أجل  $b$  نضرب دائما المعادلة (4.4) بالمصفوفة المتناظرة والخاملة  $M_Z$  والمعرفة على الشكل:

$$M_Z = I - Z(Z'Z)^{-1} Z' \dots (4.15)$$

حيث نجد أن:

$$M_Z Y = M_Z Xb + e \dots (4.16)$$

$$M_Z e = e, \quad M_Z Z = 0 \quad \text{لأن:}$$

وبضرب المعادلة (16.4) بالمصفوفة  $X'$  تصبح:

$$X'M_Z Y = X'M_Z Xb + X'e = X'M_Z Xb \dots (4.17)$$

ثم إذا كانت  $X'M_Z X$  غير شاذة نجد:

$$b = (X'M_Z X)^{-1} X'M_Z Y \dots (4.18)$$

وإذا بحثنا في العلاقة التي تربط الإنحدارين (1.4) و (2.4)، سوف نجد أن المقدّر  $b$  والبواقي  $e$ ، المحصلين من المعادلة (2.4)، يختلفان عن المقدّر  $\hat{\beta}$  والبواقي  $\hat{U}$  الناتجين من تقدير المعادلة (1.4) كمايلي:

نضرب المعادلة (4.4) بـ  $X'$  لنجد  $X'Y = X'Xb + X'Z\tau$  ومنه يكون:

$$b = (X'X)^{-1} X'Y - (X'X)^{-1} X'Z\tau = AY - AZ\tau$$

$$= A(Y - Z\tau)$$

$$= \hat{\beta} - AZ\tau$$

ليصبح:

$$\hat{\beta} = b + AZ\tau \dots (4.19)$$

ومنه نلاحظ أن  $\hat{\beta} = b$  إذا وفقط إذا كانت  $\tau = 0$ ، أو  $X'Z = 0$ .

وهذا صعب الحدوث عمليا. وعلى العموم، يكون  $\hat{\beta}$  مختلفا عن  $b$ . كما أن البواقي  $\hat{U}$  في (3.4) سوف تختلف عن مثيلتها في (4.4). والحالة الوحيدة التي تتساوى فيها بواقي الإنحدارين هي لما  $\tau = 0$ . ونضرب، كالعادة، المعادلة (4.4) بالمصفوفة  $M_X$  من (10.4) لنجد:



$$M_x Y = M_x Xb + M_x Z\tau + e.....(4.20)$$

$$= M_x Z\tau + e.....(4.21)$$

ولدينا من المعادلة (3.4)  $\hat{U} = Y - X\hat{\beta}$  . لنجد أن:

$$\hat{U} = e + M_x Z\tau.....(4.22)$$

وبناء على نتيجة البواقي بالمعادلة (22.4) يصبح RSS للنموذج (1.4) على الشكل:

$$\hat{U}'\hat{U} = e'e + \tau'Z'M_x Z\tau....(4.23)$$

$$\tau'Z'M_x e = e'M_x Z\tau = 0 \quad \text{حيث أن:}$$

$$\hat{U}'\hat{U} \geq e'e \quad \text{ولنستنتج أن:}$$

ونقول أن إضافة محدرات جديدة للنموذج يؤدي إلى تخفيض قيمة RSS وزيادة قيمة ESS. بينما حذف محدرات يؤدي إلى زيادة RSS مثلما لاحظنا بالفصل الثالث.

#### 1-1-4 النتائج الإحصائية:

نعرف، من الفصل الثالث أن النموذج الخطي العام بالمعادلة (1.4) يعطي موجهاً لمقدرات المربعات الصغرى  $\hat{\beta}$  الذي له خاصية أفضل مقدر خطي غير متحيز BLUE، تباينه  $\text{var}(\hat{\beta}) = \sigma_u^2 (X'X)^{-1}$ . وبتطبيق المربعات الصغرى على النموذج (2.4) نحصل على الموجهين  $b$ ،  $\tau$  واللذين يجب أن يحققا خاصية BLUE ماداماً يعتبران كذلك المقدرين الحقيقيين للنموذج (2.4). ومنه نبحت عن تباينهما:

$$b = (X'M_Z X)^{-1} X'M_Z Y = \beta + (X'M_Z X)^{-1} X'M_Z U$$

حيث أن  $M_Z Z = 0$ . وبإدخال التوقع الرياضي نجد:

$$E(b) = \beta + (X'M_Z X)^{-1} X'M_Z E(U) = \beta$$

أما التباين:

$$\text{var}(b) = \text{var}\left[(X'M_Z X)^{-1} X'M_Z U\right] = \sigma_u^2 (X'M_Z X)^{-1}$$

وإذا كانت لدينا العبارة:

$$X'X = X'M_Z X + X'P_Z X \dots (4.24)$$

حيث أن  $M_Z$ ،  $P_Z$  هما مصفوفتان متناظرتان وخاملتان. أما الصيغتين التربيعيتين بالمعادلة (24.4) فيمكن أن نفترض  $X'M_Z X$  بأنها محددة موجبة. بينما  $X'P_Z X$  مصفوفة موجبة شبه محددة، ومنه ينتج لدينا:

$$X'X - X'M_Z X = X'P_Z X \geq 0$$

$$(X'M_Z X)^{-1} - (X'X)^{-1} \geq 0 \text{ : لينتج أن:}$$

ومنه يكون:

$$\text{var}(b) - \text{var}(\hat{\beta}) = \sigma_u^2 \left[ (X'M_Z X)^{-1} - (X'X)^{-1} \right] \geq 0$$

$$\text{var}(b) \geq \text{var}(\hat{\beta})$$

#### 4-1-2 الحذف غير الصحيح لمحددات:

لنعتبر الآن ماذا يحدث إذا إستعملنا  $\hat{\beta}$  (من النموذج (1.4))، لما يكون النموذج الصحيح هو (2.4). ولنحلل خصائص المقدّر  $\hat{\beta}$  في هذه الحالة:

$$\hat{\beta} = AY = AX\beta + AZ\gamma + AU = \beta + AZ\gamma + AU$$

$$E(\hat{\beta}) = \beta + AZ\gamma$$

$$E(\hat{\beta} - \beta) = AZ\gamma \neq 0$$

نلاحظ أن  $\hat{\beta}$  في هذه الحالة يكون متحيزا، أما تباينه فيبقى نفسه. ومنه لا يفقد خاصية أصغر تباين أي:

$$\text{var}(\hat{\beta}) = \text{var}(AU) = \sigma_u^2 (X'X)^{-1}$$

و منه نستنتج أن الحذف غير الصحيح للمتغيرات  $Z$  (للمحدرات  $\gamma$ ) يعطي موجه مقدرات متحيزة لـ  $\beta$ ، كما أن مقدار تباين الخطأ للنموذج (1.4)، يكون متحيزا في هذه الحالة أي:

$$\hat{\sigma}_u^2 = \frac{\hat{U}'\hat{U}}{[n - (k - m)]} \dots\dots (4.25)$$

بحيث أن:

$$\begin{aligned} E(\hat{\sigma}_u^2) &= E\left(\frac{\hat{U}'\hat{U}}{n - k + m}\right) = \frac{1}{n - k + m} E(\hat{U}'\hat{U}) \\ &= \frac{1}{n - k + m} E(e'e + \tau'Z'M_X Z\tau) \\ &= \frac{1}{n - k + m} [(n - k + m)\sigma_u^2 + \gamma'Z'_X Z\gamma] \\ &= \sigma_u^2 + \frac{\gamma'Z'_X Z\gamma}{n - k + m} \neq \sigma_u^2 \end{aligned}$$



#### 3-1-4 الإضافة غير الصحيحة لمحددات جديدة:

لنعتبر الآن ماذا يحدث لـ  $b$  من النموذج (2.4) لما يكون النموذج الصحيح هو (1.4). أي لما يكون، فعلا،  $\gamma = 0$ . حيث نأخذ قيمة  $b$  المحسوبة وهي:

$$b = (X'M_Z X)^{-1} X'M_Z Y$$

ثم نستعمل المعادلة (1.4) لنعوض عن  $Y$  فنجد:

$$b = \beta + (X'M_Z X)^{-1} X'M_Z U$$

$$E(b) = \beta$$

أما التباين فهو:

$$\text{var}(b) = \text{var}[(X'M_Z X)^{-1} X'M_Z U] = \sigma_u^2 (X'M_Z X)^{-1}$$

حيث نرى في هذه الحالة أن خاصية عدم التحيز لا تتأثر، كما أن  $\text{var}(b)$  يحافظ على نفس العبارة. لكن النتيجة النهائية هي أن الحذف غير الصحيح لمجموعة محددات يعطي مقدرات متحيزة وبأصغر تباين. بينما إدخال محددات بطريقة غير صحيحة للنموذج يعطي مقدرات غير متحيزة ولكنها غير كفوة كما لاحظنا من قبل.

#### 4-1-4 إختبار الفرضية $\gamma = 0$

قد تكون عملية إضافة موجه من  $\gamma$  ( $m \times 1$ ) محددات للنموذج صحيحة، وقد تكون غير ذلك. فعليا، لا نعرف إذا كان هذا الموجه مساو للصفر أم لا. ومنه نحتاج إلى إختبار الفرضية:

$$H_0: \gamma = 0$$

$$H_A: \gamma \neq 0 \quad \text{ضد:}$$

وبالنسبة للفرضية البديلة  $H_A$  يعني أنه على الأقل عنصر واحد من الموجه  $\gamma$  يختلف عن الصفر وليس معناه أن كل عناصر  $\gamma$  غير مساوية للصفر.

وللوصول إلى ذلك نلاحظ أن:

$$\tau = (Z'M_X Z)^{-1} Z'M_X Y = \gamma + (Z'M_X Z)^{-1} Z'M_X U$$

$$E(\tau) = \gamma$$

$$\text{var}(\tau) = \text{var}\left[(Z'M_X Z)^{-1} Z'M_X U\right] = \sigma_u^2 (Z'M_X Z)^{-1}$$

و إذا كانت الأخطاء تتبع التوزيع الطبيعي المتعدد  $U \sim N(0, \sigma_u^2 I_N)$  نجد:

$$\tau \sim N\left(\gamma, \sigma_u^2 (Z'M_X Z)^{-1}\right)$$

و منه فإنه بناءا على تعريف المتغير  $\chi^2$  نجد:

$$(\tau - \gamma)' \left[ \sigma_u^2 (Z'M_X Z)^{-1} \right]^{-1} (\tau - \gamma) \sim \chi_m^2$$

و في ظل الفرضية  $H_0: \gamma = 0$  تصبح:

$$H_0: \frac{\tau' (Z'M_X Z) \tau}{\sigma_u^2} \sim \chi_m^2$$

ثم لدينا من الفرضية البديلة  $H_A$  (نموذج (2.4)) لنحصل على:

$$H_A: \frac{e'e}{\sigma_u^2} = \frac{(n-k)\hat{\sigma}_u^2}{\sigma_u^2} \sim \chi_{n-k}^2$$

و من المعادلة (23.4) لدينا:

$$e'e = \hat{U}'\hat{U} - \tau'Z'M_X Z\tau \dots (4.26)$$

$$\hat{U}'\hat{U} - e'e = \tau'Z'M_X Z\tau \geq 0$$

لنكون الاختبار الإحصائي:

$$\frac{\tau'(Z'M_x Z)\tau/m}{e'e/(n-k)} \sim F_{m, n-k}$$

$$\frac{(\hat{U}'\hat{U} - e'e)/m}{e'e/(n-k)} \sim F_{m, n-k}$$

$$\frac{(RRSS - URSS)/m}{URSS/(n-k)} \sim F_{m, n-k}$$

حيث أن  $RRSS$  هي مجموع مربعات البواقي المقيدة في ظل  $H_0$  صحيحة من النموذج (1.4) أي  $Restricted Residual Sum of Squares$ . أما  $URSS$  فهي مجموع مربعات البواقي غير المقيدة في ظل  $H_A$  صحيحة من النموذج (2.4) أي  $Unrestricted RSS$ .

#### 2-4 تقدير القيود الخطية:

مثلاً أشرنا بالفصل الثالث عند إختبارنا للفرضيات، فإن مبادئ النظرية الإقتصادية قد تجبرنا على فرض بعض القيود على معالم النموذج. وسنكتفي بالقيود الخطية في موضوعنا هذا، ولتقدير النموذج في ظل القيود الخطية نقول أن هناك تقنيتان متكافئتان وهما:

#### 1-2-4 تقنية التعويض:

لنفرض أننا نريد تقدير المعادلة التالية:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t \dots (4.27)$$

تبعاً للقيود الخطية على المعالم  $\beta_2 + \beta_3 = 1$ .



إن أحسن مثال على ذلك هو لما تكون المعادلة (27.4) تمثل لوغاريتم دالة الإنتاج. ومنه يكون النموذج المقدّر هو دالة كوب-دوغلاس للإنتاج. كما أن القيود المفروضة أعلاه تمثل قانون ثبات الغلة. وبتطبيق قانون المربعات الصغرى المتمثل في تصغير RSS تبعا للقيد  $\hat{\beta}_2 + \hat{\beta}_3 = 1$  نجد:

$$S = \text{Min} \sum \left( Y_t - \hat{\beta}_1 - \hat{\beta}_2 X_{2t} - (1 - \hat{\beta}_2) X_{3t} \right)^2 \dots\dots (4.28)$$

و التي تعطي بدورها:

$$S = \text{Min} \sum \left( Y_t - X_{3t} - \hat{\beta}_1 - \hat{\beta}_2 (X_{2t} - X_{3t}) \right)^2 \dots\dots (4.29)$$

كما نلاحظ بأن المعادلة (29.4) تعني إنحدار الملاحظات  $(Y_t - X_{3t})$  في الملاحظات  $(X_{2t} - X_{3t})$  بالإضافة إلى الحد الثابت أي:

$$(Y_t - X_{3t}) = \beta_1 + \beta_2 (X_{2t} - X_{3t}) + u_t$$

$$Y_t^* = \beta_1 + \beta_2 X_{2t}^* + u_t \dots\dots (4.30)$$

حيث أن:

$$Y_t^* = Y_t - X_{3t}$$

$$X_{2t}^* = X_{2t} - X_{3t}$$

و منه، فلتقدير المعادلة الأصلية (27.4) تبعا للقيود الخطية  $\beta_2 + \beta_3 = 1$ ، فإننا ببساطة نقدر النموذج (30.4) أعلاه من أجل الحصول على المقدرات  $\hat{\beta}_2$ ،  $\hat{\beta}_1$ ، ومن ثم نستطيع الحصول على مقدر لـ  $\hat{\beta}_3$  على النحو:

$$\hat{\beta}_3 = 1 - \hat{\beta}_2$$

أما إذا وضعنا  $\beta_2 = 1 - \beta_3$  من القيد السابق  $\beta_2 + \beta_3 = 1$ ، فإنه يمكننا صياغة أو تقدير المعادلة التالية:

$$(Y_t - X_{2t}) = \beta_1 + \beta_3 (X_{3t} - X_{2t}) + u_t \dots\dots (4.31)$$

و بإتباع نفس الطريقة نحصل على المقدرات  $\hat{\beta}_1, \hat{\beta}_2$ ، ثم نعوض لنحصل على  $\hat{\beta}_2 = 1 - \hat{\beta}_3$ . لنعتبر النموذج السابق في المعادلة (27.4). حيث نقوم بتقدير هذه المعادلة تبعا للقيد  $\beta_2 = \beta_3$  وبتطبيق طريقة التعويض نجد:

$$Y_t = \beta_1 + \beta_2 (X_{2t} + X_{3t}) + u_t \dots (4.32)$$

$$Y_t = \beta_1 + \beta_2 Z_t + u_t$$

$$Z_t = X_{2t} + X_{3t} \quad \text{حيث أن}$$

ثم نواصل تطبيق قانون المربعات الصغرى لنحصل على  $\hat{\beta}_1, \hat{\beta}_2$ .

#### 2-2-4 إختبار مجموعة قيود خطية:

إن أحد الأسباب المعروفة في تقدير المعادلة تبعا لمجموعة قيود خطية، هو من أجل الوصول إلى إقتراح إختبار لإمكانية وجود هذه القيود. ولناخذ الطريقة المباشرة في تكوين هذا الإختبار وهي قيد الصفر. فإذا فرضنا أننا نقدر المعادلة:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \gamma_1 Q_{1t} + \gamma_2 Q_{2t} + \gamma_3 Q_{3t} + u_t \dots (4.33)$$

حيث أن  $Q_j$  ( $j = 1, 2, 3$ ) هي ثلاثة متغيرات وهمية <sup>(2)</sup> تسمح بالتغير الموسمي.

و يمكن أن نختبر الفرضية القائلة بأنه لا توجد تغيرات موسمية في الحد الثابت

$$\gamma_1 = \gamma_2 = \gamma_3 = 0 \dots (4.34)$$

لتكون المعادلة المقيدة هي (27.4) سابقا:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t$$

و لإختبار صحة القيد السابق (34.4) نتبع الخطوات التالية:

(1) أفرض القيود المراد إختبارها على المعادلة لتحصل على الشكل المقيد للمعادلة. ثم قدر هذه الأخيرة بواسطة المربعات الصغرى، وأحسب RSS.

<sup>2</sup> - سنتطرق بالتفصيل لموضوع المتغيرات الوهمية في الفقرات اللاحقة.



(2) قدر النموذج العادي في (33.4)، ثم أحسب URSS

(3) كون الإحصاء التالية:

$$F = \frac{(RRSS - URSS)/m}{URSS/(n - k)} \sim F_{m, n - k} \dots (4.35)$$

أو ما يكافئها:

$$F = \frac{(R_U^2 - R_R^2)/m}{(1 - R_U^2)/(n - k)} \sim F_{m, n - k}$$

حيث  $m$  هي عدد القيود المفروضة على النموذج، أو الفرق ما بين عدد المعالم في النموذجين المقيد وغير المقيد. أما  $R_U^2$ ،  $R_R^2$  فيشيران إلى معاملي التحديد في النموذجين غير المقيد والمقيد على الترتيب. فإذا كانت القيود المفروضة مقبولة (أي  $H_0$  صحيحة)، فإننا ننتظر من الشكل المقيد وغير المقيد أن يعطيا نتائج متقاربة، أي أننا ننتظر من  $RRSS$  و  $URSS$  أن يكونا متساويين. وبالتالي تكون قيمة الإحصاء  $F$  موجبة وقريبة من الصفر. أما إذا كانت القيود غير صحيحة ( $H_0$  مرفوضة)، فإننا ننتظر أن تكون  $RRSS$  أكبر من  $URSS$  ومنه تكون الإحصاء  $F$  أكبر من الصفر.

#### 3-2-4 اختبار القيود الفردية

في حالة اختبارنا لقيد فردي، هناك طريقة بديلة لتحاكي تقدير النموذج المقيد للمعادلة الأصلية. حيث يمكن تقدير التباينات والتباينات المشتركة للمعالم المقيدة نظرا للتطور التكنولوجي في أجهزة الكمبيوتر. ونعود للمعادلة (27.4) ونفرض القيد  $\beta_2 + \beta_3 = 1$ .

وإذا كتبنا  $\beta_2 + \beta_3 = \gamma$ ، فإن القيد السابق يصبح على الشكل:  $H_0: \gamma = 1$ . وبتطبيق قانون المربعات الصغرى على المعادلة (27.4)، غير المقيدة، تكون المقدرة  $\hat{\gamma}$  تتبع التوزيع الطبيعي ونحصل على الاختبار الإحصائي:



$$t_{n-3} = \frac{\hat{\gamma} - 1}{SE(\hat{\gamma})} = \frac{(\hat{\beta}_2 + \hat{\beta}_3) - 1}{SE(\hat{\beta}_2 + \hat{\beta}_3)}$$

وفي ظل الفرضيات الأساسية لمقدرات المربعات الصغرى، تكون المقدرتين  $\hat{\beta}_2$  و  $\hat{\beta}_3$  غير متحيزين ليكون  $\hat{\beta}_2 + \hat{\beta}_3$  مقدرا غير متحيز لـ  $\beta_2 + \beta_3$  كذلك. ومادام  $\hat{\beta}_2$  و  $\hat{\beta}_3$  يتبعان التوزيع الطبيعي، فإن حاصل جمعهما يتبع التوزيع الطبيعي كذلك. لنجد:

$$\frac{(\hat{\beta}_2 + \hat{\beta}_3) - (\beta_2 + \beta_3)}{\sqrt{\text{var}(\hat{\beta}_2 + \hat{\beta}_3)}} \sim N(0,1)$$

حيث أن:

$$\text{var}(\hat{\beta}_2 + \hat{\beta}_3) = \text{var}(\hat{\beta}_2) + \text{var}(\hat{\beta}_3) + 2 \text{cov}(\hat{\beta}_2, \hat{\beta}_3)$$

وبتعويض  $\sigma_u^2$  الموجودة في التباينات والتباينات المشتركة أعلاه بمقدرها غير المتحيز  $\hat{\sigma}_u^2$  نجد:

$$\frac{(\hat{\beta}_2 + \hat{\beta}_3) - (\beta_2 + \beta_3)}{\sqrt{\hat{\text{var}}(\hat{\beta}_2 + \hat{\beta}_3)}} = \frac{\hat{\beta}_2 + \hat{\beta}_3 - 1}{SE(\hat{\beta}_2 + \hat{\beta}_3)} \sim t_{n-3} \dots (4.36)$$

#### 4-2-4 تقنية مضاعفات لأقرايج

لنعود إلى نموذج المعادلة (26.3) بالفصل الثالث ونفرض عليه مجموعة

القيود الخطية:

$$H_0: R\beta = r$$

حيث أن كلا من  $R$  و  $r$  معرفتين سابقا. ويستوجب علينا الآن، إيجاد مقدر لموجه المعالم  $\beta$  والذي يوافق مجموعة القيود الخطية المفروضة على النموذج. ومنه نقوم باختيار هذا الموجه الذي يقوم بتصغير  $RSS$  تبعا للقيود:

$$R\beta = r$$

ونقوم بتعريف العبارة اللاقراطية على الشكل:

$$S(\beta, \lambda) = (Y - X\beta)'(Y - X\beta) - \lambda'(R\beta - r)$$

حيث أن  $\lambda$  هي  $m \times 1$  موجه عمود لمضاعفات لا قراتج. وبالإشتقاق الجزئي لهذه العبارة بالنسبة لـ  $\beta$ ،  $\lambda$  على الترتيب نجد:

$$\frac{\partial S}{\partial \beta} = -2X'Y + 2X'X\beta - R'\lambda$$

$$\frac{\partial S}{\partial \lambda} = -(R\beta - r)$$

وبضرب المعادلة الجزئية الأولى بالعبارة  $R(X'X)^{-1}$  ومساواتها بالصفر نجد:

$$-2R(X'X)^{-1}X'Y + 2R\beta - R(X'X)^{-1}R'\lambda = 0$$

مع  $\hat{\beta} = (X'X)^{-1}X'Y$  و  $R\beta = r$  نجد:

$$-2R\hat{\beta} + 2r - R(X'X)^{-1}R'\lambda = 0$$

$$\lambda = -2[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)$$

وبتعويض  $\lambda$  في المشتقة الجزئية الأولى من جديد نجد:

$$-2X'Y + 2X'X\hat{\beta} + 2R'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r) = 0$$

$$X'X\beta = X'Y - R'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)$$

ومنه يكون مقدار المربعات الصغرى المقيد على الشكل:

$$\hat{\beta}_R = \hat{\beta} - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r) \dots (4.37)$$

وبالتعويض عن  $\hat{\beta} = \beta + AU$  نجد:

$$\begin{aligned}\hat{\beta}_R &= \beta + AU - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}RAU \\ &= \beta + \left[ I - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}R \right]AU\end{aligned}$$

$$\hat{\beta}_R = \beta + HAU \dots (4.38)$$

حيث أن:

$$H = \left[ I - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}R \right] \dots (4.39)$$

$$E(\hat{\beta}_R) = \beta + HAE(U) = \beta$$

وبالتالي فإن مقدار المربعات الصغرى المقيد  $\hat{\beta}_R$  هو مقدار غير متحيز لـ  $\beta$ . أما مصفوفة التباين-التباين المشترك فهي:

$$\text{var}(\hat{\beta}_R) = \text{var}(HAU) = \sigma_u^2 HAA'H' = \sigma_u^2 H(X'X)^{-1}H' \dots (4.40)$$

ويمكن كتابتها كذلك على الشكل:

$$\text{var}(\hat{\beta}_R) = \sigma_u^2 H(X'X)^{-1} \quad (3)$$

ولمناقشة المعنوية الإحصائية لموجه المقدرات المقيدة  $\hat{\beta}_R$  نختبر الفرضية

$$H_0: R\beta = r$$

$$H_A: R\beta \neq r \quad \text{ضد:}$$

ثم نلاحظ أن:

$$U \sim N(0, \sigma_u^2 I_N)$$

$$\hat{\beta} \sim N(\beta, \sigma_u^2 (X'X)^{-1}) \quad \text{يؤدي إلى:}$$

ومن المعادلتين (58.3) و (59.3) بالفصل الثالث لدينا تحت  $H_0$  صحيحة:

$$R\hat{\beta} \sim N(r, \sigma_u^2 R(X'X)^{-1}R')$$

<sup>3</sup>- يمكن للقارئ التأكد من ذلك عن طريق تعويض قيمة  $H$  المعرفة في (39.4) بالمعادلة (40.4).



$$R\hat{\beta} - r \sim N(0, \sigma_u^2 R(X'X)^{-1} R')$$

أي: لنكون المتغير العشوائي  $\chi^2$  على الشكل:

$$H_0: (R\hat{\beta} - r)' \left[ \sigma_u^2 R(X'X)^{-1} R' \right]^{-1} (R\hat{\beta} - r) \sim \chi_m^2$$

$$H_A: \frac{\hat{U}'\hat{U}}{\sigma_u^2} = \frac{U'MU}{\sigma_u^2} \sim \chi_{n-k}^2$$

وإذا كانت  $\chi_m^2$  مستقلة عن  $\chi_{n-k}^2$ ، فإننا نكون الإختبار الإحصائي الموجود بالمعادلة (63.3) على الشكل:

$$\frac{(R\hat{\beta} - r)' \left[ R(X'X)^{-1} R' \right]^{-1} (R\hat{\beta} - r) / m}{\hat{U}'\hat{U} / (n - k)} \sim F_{m, n-k} \dots (4.42)$$

وبناء على تعريف الصيغتين التربيعيتين  $z'Mz$ ،  $z'Dz$  بالفصل الثالث والنتيجة الموجودة بالمعادلة (64,3) حيث أن إستقلال الصيغتين التربيعيتين أعلاه يعني أن  $DM = 0$  فإننا نكتب:

$$R\hat{\beta} - r = R(\hat{\beta} - \beta) = RAU$$

لنجد:

$$\begin{aligned} & \frac{1}{\sigma_u^2} (R\hat{\beta} - r)' \left[ R(X'X)^{-1} R' \right]^{-1} (R\hat{\beta} - r) \\ &= \frac{1}{\sigma_u^2} U'A'R' \left[ R(X'X)^{-1} R' \right]^{-1} RAU \end{aligned}$$

$$= \left( \frac{U}{\sigma_u} \right)' \left[ A'R'(R(X'X)^{-1}R')^{-1}RA \right] \left( \frac{U}{\sigma_u} \right)$$

$$= \left( \frac{U}{\sigma_u} \right)' D \left( \frac{U}{\sigma_u} \right) = z'Dz \dots (4.43)$$

حيث أن  $D = A'R'[R(X'X)^{-1}R']^{-1}RA$  وهي مصفوفة متناظرة وخاملة. أما الموجه  $z$  فهو:

$$z = \frac{U}{\sigma_u} \sim N(0, I_n) \dots (4.44)$$

كما أنه يمكن كتابة URSS على الشكل:

$$\frac{\hat{U}'\hat{U}}{\sigma_u^2} = \frac{U'MU}{\sigma_u^2} = \left( \frac{U}{\sigma_u} \right)' M \left( \frac{U}{\sigma_u} \right) = z'Mz \dots (4.45)$$

وللتأكد من إستقلالية البسط عن المقام في المعادلة (42.4) نلاحظ:

$$D.M = A'R'[R(X'X)^{-1}R']^{-1}RAM = 0$$

$$AM = (X'X)^{-1}X'M = 0 \quad \text{لأن:}$$

ونستنتج أن العبارة (42.4) صحيحة.

ولنعتبر الآن البواقي الناتجة عن التقدير المقيد:

$$\hat{U}_R = Y - X\hat{\beta}_R = Y - X \left[ \hat{\beta} - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r) \right]$$

$$= (Y - X\hat{\beta}) + X(X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}RAU$$

$$\hat{U}_R = \hat{U} + A'R'[R(X'X)^{-1}R']^{-1}RAU$$

$$\hat{U}_R = \hat{U} + DU$$

ولنكون مجموع مربعات البواقي المقيدة RRSS

$$\begin{aligned} RRSS &= \hat{U}'_R \hat{U}_R = [\hat{U} + DU]' [\hat{U} + DU] \\ &= \hat{U}'\hat{U} + \hat{U}'DU + U'D'\hat{U} + U'D'DU \end{aligned}$$

الشيء الذي يعني:  $RRSS = \hat{U}'\hat{U} + U'DU$  أي أن:

$$RRSS = URSS + U'DU$$

$$= URSS + (R\hat{\beta} - r)' [R(X'X)^{-1}R']^{-1} (R\hat{\beta} - r)$$

ومنه تكتب:

$$\frac{RRSS - URSS}{\sigma_u^2} = \frac{1}{\sigma_u^2} (R\hat{\beta} - r)' [R(X'X)^{-1}R']^{-1} (R\hat{\beta} - r) \sim \chi_m^2$$

$$\frac{URSS}{\sigma_u^2} \sim \chi_{n-k}^2$$

لتصبح النسبة:

$$\begin{aligned} \frac{\chi_m^2/m}{\chi_{n-k}^2/(n-k)} &= \frac{(RRSS - URSS)/m}{URSS/(n-k)} \\ &= \frac{(R\hat{\beta} - r)' [R(X'X)^{-1}R']^{-1} (R\hat{\beta} - r)/m}{\hat{\sigma}_u^2} \sim F_{m,n-k} \dots (4.46) \end{aligned}$$



- وتعرف هذه الطريقة بتحليل التباين. وهي طريقة قوية حيث تقترح شرحا بديلا للاختبار الإحصائي الموجود بالمعادلة (63.3) والمعتمد على توزيع الموجه  $R\hat{\beta}$  الذي له وسط  $\Gamma$  ومصفوفة تباين هي  $\sigma^2 R(X'X)^{-1}R'$ .

- إن إحدى التطبيقات لتحليل التباين هي الحالة الخاصة والمذكورة بالفصل الثالث مثل القيد  $\beta_j = 0 \quad j = 1, 2, \dots, k$ . حيث تكون المصفوفة  $R$  في هذه الحالة عبارة عن موجه سطر على الشكل  $(0 \dots 0 \ 1 \ 0 \dots 0)$ . والتي تعني أنها تحتوي على أصفار ماعدا العنصر  $j$  والمساوي للواحد، بينما الموجه  $\Gamma$  يكون هنا عبارة عن رقم سلمي  $Scalar$  والمساوي للصفر.

#### 3-4 التنبؤ في ظل النموذج الخطي العام:

تطرقنا في الفصل الثاني لموضوع التنبؤ بملاحظة المتغير التابع  $Y_i$  في فترة مستقبلية معينة، ولتكن النقطة  $(f)$ ، وذلك بمعرفتنا المسبقة لقيمة المتغير المستقل في تلك الفترة  $X_f$ . وهذا ما يسمى بالتنبؤ النقطي. أما بالنسبة للنموذج الخطي العام، فنتطرق إلى قضية التنبؤ بالملاحظات المستقبلية (أو خارج العينة) لموجه الملاحظات الخاصة بالمتغير التابع وذلك بمعرفتنا لمصفوفة ملاحظات المتغيرات المستقلة والمستقبلية. ويسمى هذا النوع من التنبؤ بالتنبؤ بمجال. فليكن النموذج الخطي العام خلال العينة  $n$  والمقدر على الشكل:

$$\hat{Y} = X\hat{\beta}$$

ومقدر المربعات الصغرى العادية  $\hat{\beta} = AY$ . ويكون المقدر بملاحظة واحدة في المستقبل هو:

$$\hat{Y}_{n+1} = \hat{\beta}_1 + \hat{\beta}_2 X_{2,n+1} + \dots + \hat{\beta}_k X_{k,n+1}$$

أما التنبؤ بعد فترتين في المستقبل:

$$\hat{Y}_{n+2} = \hat{\beta}_1 + \hat{\beta}_2 X_{2,n+2} + \dots + \hat{\beta}_k X_{k,n+2}$$

ونواصل هكذا إلى أن نصل إلى التنبؤ بالفترة  $m$  في المستقبل:

$$\hat{Y}_{n+m} = \hat{\beta}_1 + \hat{\beta}_2 X_{2,n+m} + \dots + \hat{\beta}_k X_{k,n+m}$$

إن إذا أردنا التنبؤ بمجموعة من الملاحظات المستقبلية (التنبؤ بمجال) بفترة

تساوي  $m$  ملاحظة مرة واحدة. يكون موجه القيم التقديرية المتنبأ بها هو:

$$\hat{Y}_n^m = \begin{bmatrix} \hat{Y}_{n+1} \\ \hat{Y}_{n+2} \\ \vdots \\ \vdots \\ \hat{Y}_{n+m} \end{bmatrix}$$

- أما مصفوفة ملاحظات المتغيرات المستقلة والمستقبلية فهي:

$$X_n^m = \begin{bmatrix} 1 & X_{2,n+1} & \dots & X_{k,n+1} \\ 1 & X_{2,n+2} & \dots & X_{k,n+2} \\ \vdots & & & \\ \vdots & & & \\ 1 & X_{2,n+m} & \dots & X_{k,n+m} \end{bmatrix}$$

ومنه يمكن كتابة النموذج الخطي العام المتنبأ به على الشكل:

$$Y_n^m = X_n^m \beta + U_n^m \dots (4.47)$$

حيث أن  $Y_n^m$  هي  $m \times 1$ ، و  $X_n^m$  هي  $m \times k$ ،  $U_n^m$  هي  $m \times 1$ . كما أن

النموذج المقدر للمعادلة (47.4) هو  $\hat{Y}_n^m = X_n^m \hat{\beta}$ . ويكون وسط مقدر التنبؤ

هو:

$$E(\hat{Y}_n^m) = X_n^m E(\hat{\beta}) = X_n^m \beta = E(Y_n^m)$$

$$E(\hat{Y}_n^m) = E(Y_n^m) = X_n^m \beta \quad \text{إذن نستنتج أن:}$$

ومنه نقول أن  $\hat{Y}_n^m$  هو تنبؤ خطي غير متحيز للعبارة  $E(Y_n^m) = X_n^m \beta$  ليكون التباين:

$$\begin{aligned} \text{var}(\hat{Y}_n^m) &= E\left[(\hat{Y}_n^m - X_n^m \beta)(\hat{Y}_n^m - X_n^m \beta)'\right] \\ &= \sigma_u^2 X_n^m (X'X)^{-1} X_n^{m'} \dots (4.48) \end{aligned}$$

لنعرف، موجه أخطاء التنبؤ على الشكل:

$$d = Y_n^m - \hat{Y}_n^m \dots (4.49)$$

$$E(d) = E(Y_n^m - \hat{Y}_n^m) = 0$$

أما التباين فهو:

$$\begin{aligned} \text{var}(d) &= \text{var}(Y_n^m - \hat{Y}_n^m) = \\ &= E\left[-X_n^m(\hat{\beta} - \beta) + U_n^m\right]\left[-X_n^m(\hat{\beta} - \beta) + U_n^m\right]' \\ &= E\left[X_n^m(\hat{\beta} - \beta)(\hat{\beta} - \beta)'X_n^{m'} + U_n^m U_n^{m'} - X_n^m(\hat{\beta} - \beta)U_n^{m'} - U_n^m(\hat{\beta} - \beta)'X_n^{m'}\right] \end{aligned}$$

وإذا كانت فرضا العبارة التالية:

$$E(UU') = \sigma_u^2 I_n, \quad E(U_n^m U_n^{m'}) = \sigma_u^2 I_m$$

ثم فرضنا أن:

$$E\begin{pmatrix} U \\ U_n^m \end{pmatrix} \begin{pmatrix} U' & U_n^{m'} \end{pmatrix} = \begin{bmatrix} E(UU') & E(UU_n^{m'}) \\ E(U_n^m U') & E(U_n^m U_n^{m'}) \end{bmatrix} = \sigma_u^2 I_{n+m}$$

لأن  $E(UU_n^{m'}) = E(U_n^m U') = 0$  بناء على الفرضية

$$i \neq j: E(u_i u_j) = 0 \quad \text{لنستنتج أن:}$$



$$E[X_n^m (\hat{\beta} - \beta) U_n'^m] = X_n^m E(AU U_n'^m) \\ = X_n^m A E(U U_n'^m) = 0$$

ليكون تباين موجه خطأ التنبؤ على الشكل:

$$\text{var}(d) = \sigma_u^2 X_n^m (X'X)^{-1} X_n'^m + \sigma_u^2 I_m \dots (4.49)'$$

ويكون هذا التنبؤ هو أحسن تنبؤ خطي غير متحيز يمكن الحصول عليه أي له خاصية BLUP. حيث إذا عرفنا  $\tilde{Y}_n^m$  في شكل خطي لعينة ملاحظات المتغير التابع مع وسط لخطأ التنبؤ مساو للصفر  $E(Y_n^m - \tilde{Y}_n^m) = 0$ ، لدينا المتراحة:

$$\text{var}(Y_n^m - \tilde{Y}_n^m) - \text{var}(Y_n^m - \hat{Y}_n^m) \geq 0$$

ومنه نستنتج أن  $\hat{Y}_n^m = X_n^m \hat{\beta}$  هو أحسن تنبؤ خطي غير متحيز.

وتكون إختبارات التنبؤ عن طريق إيجاد التوزيع الذي يعتبر فرضية العدم والقائلة بأن النموذج الخطي العام يبقى محافظا على شكله من الملاحظة الأولى إلى الملاحظة  $n + m$  في المستقبل. أي نفترض عدم تغير البناء الهيكلي للنموذج، ونكتبه:

$$H_0: \hat{Y} = X\hat{\beta} : i = 1, 2, \dots, n, n+1, \dots, n+m$$

وذلك ضد الفرضية البديلة، والتي تقول أن نموذج العينة الأولى  $n$  يختلف عن نموذج التنبؤ للفترة  $m$ .

وللوصول إلى التوزيع المناسب لهذه الفرضية نلاحظ أن:

$$\begin{pmatrix} U \\ U_n^m \end{pmatrix} \sim N(0, \sigma_u^2 I_{n+m})$$

$$d = Y_n^m - \hat{Y}_n^m = -X_n^m (\hat{\beta} - \beta) + U_n^m = -X_n^m A U + U_n^m \dots (4.50) \\ d \sim N[0, \sigma_u^2 (X_n^m (X'X)^{-1} X_n'^m + I_m)]$$

ومن تعريف المتغير العشوائي  $\chi^2$  لدينا:

$$d'[\text{var}(d)]^{-1}d \sim \chi_m^2 \dots\dots\dots (4.51)$$

حيث أن  $m$  هنا هي رتبة  $\text{var}(d)$  ن نجد أن:

$$(Y_n^m - \hat{Y}_n^m)' [\sigma_u^2 X_n^m (X'X)^{-1} X_n^{m'} + \sigma_u^2 I_m]^{-1} (Y_n^m - \hat{Y}_n^m) \sim \chi_m^2$$

ولدينا خلال فترة العينة  $n$  مايلي:

$$\frac{\hat{U}'\hat{U}}{\sigma_u^2} = \frac{U'MU}{\sigma_u^2} = \frac{1}{\sigma_u^2} \begin{pmatrix} U' & U_n^{m'} \end{pmatrix} \begin{bmatrix} M & 0 \\ 0 & 0 \end{bmatrix} \begin{pmatrix} U \\ U_n^m \end{pmatrix} \sim \chi_{n-k}^2 \dots\dots\dots (4.52)$$

$$M = I - X(X'X)^{-1}X' \quad \text{حيث أن:}$$

وبتحليل موجه أخطاء التنبؤ على الشكل:

$$d = \begin{bmatrix} -X_n^m A U + U_n^m \end{bmatrix} = \begin{bmatrix} -X_n^m A & I_m \end{bmatrix} \begin{bmatrix} U \\ U_n^m \end{bmatrix}$$

لتكون العبارة (51.4) على الشكل:

$$\frac{1}{\sigma_u^2} \begin{pmatrix} U' & U_n^{m'} \end{pmatrix} \begin{bmatrix} -A' X_n^{m'} \\ \dots \\ I_m \end{bmatrix} \left[ X_n^m (X'X)^{-1} X_n^{m'} + I_m \right]^{-1} \begin{bmatrix} -X_n^m A & I_m \end{bmatrix} \begin{bmatrix} U \\ U_n^m \end{bmatrix} \sim \chi_m^2$$

ولنعرف

$$Z = \frac{1}{\sigma_u} \begin{pmatrix} U \\ U_n^m \end{pmatrix} \sim N(0, I_{n+m})$$

وبذلك:

$$D = \begin{bmatrix} -A'X_n^m \\ \dots \\ I_m \end{bmatrix} \left[ X_n^m (X'X)^{-1} X_n^m + I_m \right]^{-1} \begin{bmatrix} -X_n^m A & : & I_m \end{bmatrix}$$

لتصبح العبارة (51.4) والعبارة (52.4) على التوالي:

$$z'Dz \sim \chi_m^2$$

$$z'M'z \sim \chi_{n-k}^2$$

حيث أن  $D$ ،  $M$  مصفوفتان متناظرتان وخاملتان. ومنه نجد:

$$D.M = \begin{bmatrix} -A'X_n^m \\ \dots \\ I_n \end{bmatrix} \left[ X_n^m (X'X)^{-1} X_n^m + I_m \right]^{-1} \begin{bmatrix} X_n^m A & : & I_m \end{bmatrix} \begin{bmatrix} M & 0 \\ 0 & 0 \end{bmatrix} = 0$$

ليصبح  $\chi_m^2$  مستقلا عن  $\chi_{n-k}^2$  ونكون الإحصاءة التالية:

$$F = \frac{\chi_m^2/m}{\chi_{n-k}^2/(n-k)} = \frac{z'Dz/m}{z'Mz/(n-k)} = \frac{(Y_n^m - \hat{Y}_n^m)' [X_n^m (X'X)^{-1} X_n^m + I_m]^{-1} (Y_n^m - \hat{Y}_n^m)/m}{\hat{\sigma}_u^2} \sim F_{m,n-k} \dots (4.53)$$

وإذا كانت  $m = 1$  (التنبؤ بالنقطة) يصبح التوزيع أعلاه على الشكل:

$$\frac{(Y_{n+1} - \hat{Y}_{n+1})' [X_{n+1} (X'X)^{-1} X_{n+1}' + 1]^{-1} (Y_{n+1} - \hat{Y}_{n+1})}{\hat{\sigma}_u^2} \sim F_{1,n-k} = t_{n-k}^2$$

إن أبسط ملاحظة نستطيع إستنتاجها هي وجود إنحدارين مختلفين، حيث لما تكون فرضية العدم هي الصحيحة (الشكل الهيكلي للنموذج لا يتغير في الفترة  $m$ ) نقوم بتقدير  $Y$  في المتغيرات المستقلة مستعملين كل الملاحظات الحاضرة والمستقبلية أي حجم العينة  $n + m$  لنحصل على مجموع مربعات البواقي المقيدة  $RRSS$ . بينما يتعلق الإنحدار الثاني بالبواقي غير المقيدة  $URSS$ . ثم نكون الإختبار التالي:



$$F = \frac{(RRSS - URSS)/m}{URSS/(n - k)} \sim F_{m, n-k} \dots (4.54)$$

ويمكن إعادة صياغة نموذج العينة  $n$  على الشكل:

$$Y_1 = X_1\beta_1 + U_1$$

أما نموذج التنبؤ بالمعادلة (47.4) فيكتب على الشكل:

$$Y_2 = X_2\beta_2 + U_2$$

وتكون الفرضية المختبرة هي:  $H_0: \beta_1 = \beta_2$

ومن أجل التنبؤ النقطي نستعمل تنبؤ المربعات الصغرى المعتمد على  $\hat{\beta}_1$ :

$$\hat{Y}_2 = X_2\hat{\beta}_1 = X_2(X_1'X_1)^{-1}X_1'Y_1 = X_2A_1Y_1$$

إن هذا المقدّر هو دالة خطية لـ  $Y_1$  (فترة العينة  $n$ ). ومنه يكون التنبؤ غير

المتحيز لـ  $Y_2$  إذا كانت  $\beta_1 = \beta_2$  هو على الشكل:

$$E(\hat{Y}_2) = E(X_2\hat{\beta}_1) = X_2\beta_1 = E(Y_2)$$

ولتكوين التنبؤ بمجال نعرف موجه أخطاء التنبؤ كما في المعادلة (49.4):

$$d = (Y_2 - \hat{Y}_2) = Y_2 - X_2\hat{\beta}_1 = X_2\beta_2 - X_2\hat{\beta}_1 + U_2$$

$$= X_2\beta_2 + U_2 - X_2(\beta_1 + A_1U_1)$$

$$= X_2\beta_2 - X_2\beta_1 + U_2 - X_2A_1U_1$$

$$A_1 = (X_1'X_1)^{-1}X_1' \quad \text{حيث أن:}$$

$$E(d) = X_2(\beta_2 - \beta_1)$$

$$E(d) = 0$$

وإذا كانت  $H_0$  صحيحة فإن:

ليكون التباين:

$$\text{var}(d) = \text{var}[U_2 - X_2A_1U_1] = \sigma_u^2[I_m + X_2(X_1'X_1)^{-1}X_2']$$

ولما  $m = 1$  فإن  $Y_2$  و  $d$  تصبح أعدادا سلمية و  $X_2$  موجه سطر، ليكون:

$$\text{var}(d) = \sigma_u^2[1 + X_2(X_1'X_1)^{-1}X_2']$$

ونكون مجال الثقة لـ  $Y_2$  من الإحصاءة  $t$  إذا كان  $\beta_2 = \beta_1$ :

$$\frac{Y_2 - X_2 \hat{\beta}_1}{\hat{\sigma}_u [1 + X_2 (X_1' X_1)^{-1} X_2']^{1/2}} = \frac{Y_2 - X_2 \hat{\beta}_1}{\sqrt{\text{var}(d)}} \sim t_{n-k} = \sqrt{F_{1,n-k}}$$

$$\hat{\sigma}_u^2 = \left( Y_1 - X_1 \hat{\beta}_1 \right)' \left( Y_1 - X_1 \hat{\beta}_1 \right) / (n - k)$$

حيث أن: ويكون 90 % مجال ثقة لـ  $Y_2$  هو:

$$-t_{n-k,0.05} \cdot \sqrt{\text{var}(d)} < Y_2 - X_2 \hat{\beta}_1 < t_{n-k,0.05} \cdot \sqrt{\text{var}(d)}$$

ليكون مجال التنبؤ النقطي هو:

$$X_2 \hat{\beta}_1 - t_{n-k,0.05} \cdot \sqrt{\text{var}(d)} < Y_2 < X_2 \hat{\beta}_1 + t_{n-k,0.05} \cdot \sqrt{\text{var}(d)}$$

أما لما  $m > 1$  نستعمل الإحصاءة الموجودة بالمعادلة (51.4) لنجد:

$$\frac{d' [\text{var}(d)]^{-1} d}{\hat{\sigma}_u^2} = \frac{\left( Y_2 - X_2 \hat{\beta}_1 \right)' \left[ 1 + X_2 (X_1' X_1)^{-1} X_2' \right] \left( Y_2 - X_2 \hat{\beta}_1 \right) / m}{\hat{\sigma}_u^2} \sim F_{m,n-k} \dots (4.55)$$

ونلاحظ أنه لما  $m \leq k$ . فإننا لا نستطيع حساب الإنحدار الثاني  $Y_2 = X_2 \beta_2 + U_2$  لأن عدد المعالم المطلوب تقديرها أكبر من حجم العينة  $m$ . ومنه تكون البواقي  $\hat{U}_2$  مساوية لموجه الأصفار. ويكون الاختبار المناسب هو ذلك المذكور أعلاه بالمعادلة (55.4) أو ذلك الموجود بالمعادلة (53.4). والمعتمد على توزيع الموجه  $d$  لأخطاء التنبؤ. كما يمكن استعمال الاختبار الموجود بالمعادلة (54.4) والمعتمد على تحليل التباين. وهما اختباران متكافئان. أما لما  $m > k$ . فيكون الاختبار المناسب لهذه الحالة من أجل الفرضية  $\beta_1 = \beta_2$  هو اختبار التغير الهيكلي للكاتب والباحث (4) G.Chow حيث يتطلب منا في هذه الحالة إجراء إنحدارين منفصلين لكل من العينة  $II$ . وفترة التنبؤ  $III$ . ولنكون بعدها مجموع مربعات البواقي غير المقيدة. بالإضافة إلى الإنحدار المقيد والذي يكون حجم عينته هو  $n + m$ . إذن تصبح لدينا ثلاثة إنحدارات منفصلة وسوف نوضحها في الفقرة القادمة لإختبارات التغير الهيكلي.

4- G.C. Chow "Econometrics" Mc-Graw-Hill inc, USA Chap 2 - Page 63. 1983.



#### 4-4 إختبارات التغير الهيكلي:

أغلبية الإتحادات التي عرفناها لحد الآن تركز على نموذج الإتحاد الخطي الفردي ومجموعات البيانات الفردية. لكن هناك أوقات نريد فيها التأكد من صلاحية النموذج لمجموعتين مختلفتين من البيانات. مثل دالة الإستهلاك الخاصة بسنوات الحرب وسنوات السلم (أي استعمال ما يسمى بالمتغيرات الوهمية). ولإختبار ما إذا كانت فرضية إختلاف نموذجي إتحاد معينين صحيحة أو لا، نبدأ عادة بفرضية العدم  $H_0$  والقائلة بأن الإتحادين متماثلين (أي أن النموذج يحافظ على نفس بنائه الهيكلي). ثم نلاحظ إذا كان بإمكاننا رفض الفرضية البديلة أم لا. إن هذا النوع من الإختبار يسمى بإختبار المساواة مابين مجموعات من معالم إتحاد أو إختبارات التغير الهيكلي أو إختبار Chow، وهو إحدى التطبيقات المهمة لتحليل التباين.

#### 1-4-4 إختبار التغير الهيكلي لنموذج بسيط:

لنعتبر إتحادين يمثلان عيّنتي ملاحظات دالة الإستهلاك الكينزية لأفراد المجتمع الجزائري خلال فترتين إقتصاديتين مختلفتين. فتخص الأولى فترة مابين 1967 و 1978،  $n_1 = 12$ . والعينة الثانية للفترة 1979-1989 ( $n_2 = 11$ ). ونريد معرفة ما إذا كان هناك تغير في دالة الإستهلاك خلال الفترتين الزمنيتين المشار إليهما، وذلك بواسطة إختبار فرضية العدم القائلة بأن معالم الإتحاد متساوية في العيّنتين. أو هل التصرف الإقتصادي للأفراد الجزائريين يبقى ثابتا عبر الزمن أم لا. ولناخذ العيّنتين  $n_1$  و  $n_2$  ونكتب دالة الإستهلاك الكينزية على الشكل:



$$\begin{cases} Y_t = \beta_1 + \beta_2 X_t + u_t : t = 67, 68, \dots, 78 \\ Y_t = \gamma_1 + \gamma_2 X_t + u_t : t = 79, \dots, 89 \end{cases} \dots\dots(4.56)$$

حيث أن  $X_t$  هي الدخل الفردي الحقيقي،  $Y_t$  الإستهلاك الفردي الحقيقي. إن المعادلة (56.4) أعلاه، تمثل النموذج غير المقيد والذي يسمح لكل من الحد الثابت والميل بأن يكونا مختلفين في الفترتين المذكورتين أعلاه. ويمكن كتابة الشكل غير المقيد في صيغة مصفوفات على النحو:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_{n_1} \end{bmatrix} = \begin{bmatrix} 1 & X_1 & 0 & 0 \\ 1 & X_2 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & X_{n_1} & 0 & 0 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \gamma_1 \\ \gamma_2 \end{bmatrix} + \begin{bmatrix} U_1 \\ U_2 \\ \vdots \\ U_{n_1} \end{bmatrix} \dots\dots(4.57)$$

$$\begin{bmatrix} Y_{n_1+1} \\ Y_{n_1+2} \\ \vdots \\ Y_{n_1+n_2} \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 & X_{n_1+1} \\ 0 & 0 & 1 & X_{n_1+2} \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 1 & X_{n_1+n_2} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \gamma_1 \\ \gamma_2 \end{bmatrix} + \begin{bmatrix} U_{n_1+1} \\ U_{n_1+2} \\ \vdots \\ U_{n_1+n_2} \end{bmatrix}$$

ويمكن كتابة النموذج (57.4) في شكل نموذج خطي عام:

$$Y = X\beta + U$$

حيث أن:

$$X = \begin{bmatrix} X_1 & 0 \\ 0 & X_2 \end{bmatrix}, \quad U = \begin{bmatrix} U_1 \\ U_2 \end{bmatrix} \quad (n_1 + n_2) \times 1$$

$$(n_1 + n_2) \times 4$$

$$\beta' = [\beta_1 \quad \beta_2 \quad \vdots \quad \gamma_1 \quad \gamma_2] = [\beta' \quad \vdots \quad \gamma'] = [Y'_1 \quad Y'_2]$$

أي بصورة مفصلة (مكافئة) كمايلي:

$$\begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} X_1 & 0 \\ 0 & X_2 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \gamma_1 \\ \gamma_2 \end{bmatrix} + U \dots (4.58)$$

لنأخذ المصفوفة  $X$  على أنها مصفوفة كتلة قطرية Block Diagonal , كما

أن المصفوفتين  $X_1, X_2$  لهما عمود  $n_1 \times 1, n_2 \times 1$  من الواحد. بالإضافة

إلى ملاحظات الدخل الفردي كمايلي:

$$X_1 = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ \vdots & \vdots \\ 1 & X_{n_1} \end{bmatrix}, \quad X_2 = \begin{bmatrix} 1 & X_{n_1+1} \\ 1 & X_{n_1+2} \\ \vdots & \vdots \\ \vdots & \vdots \\ 1 & X_{n_1+n_2} \end{bmatrix}$$

$$n_1 \times 2 \qquad n_2 \times 2$$

كما أن الموجه  $\beta$  يمثل موجه عمود  $(4 \times 1)$  لأربعة معالم هيكلية. وبتطبيق قانون المربعات الصغرى على المعادلة (58.4) نجد:

$$\hat{\beta} = (X'X)^{-1} X'Y = \begin{bmatrix} (X_1'X_1)^{-1} & 0 \\ 0 & (X_2'X_2)^{-1} \end{bmatrix} \begin{pmatrix} X_1'Y_1 \\ X_2'Y_2 \end{pmatrix}$$

لينتج مايلي:

$$\begin{pmatrix} \hat{\beta}^* \\ \hat{\gamma}^* \end{pmatrix} = \begin{bmatrix} (X_1'X_1)^{-1} X_1'Y_1 \\ (X_2'X_2)^{-1} X_2'Y_2 \end{bmatrix} \dots (4.59)$$

ومن ثم ينتج لدينا:

$$\hat{\beta}^* = \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = (X_1'X_1)^{-1} X_1'Y_1 = \begin{bmatrix} i'i & i'X_i \\ X_i'i & X_i'X_i \end{bmatrix}^{-1} \begin{pmatrix} i'Y_i \\ X_i'Y_i \end{pmatrix}$$

$$i = 1, 2, \dots, n_1$$

$$\hat{\gamma}^* = \begin{pmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \end{pmatrix} = (X_2'X_2)^{-1} X_2'Y_2 = \begin{bmatrix} i'i & i'X_i \\ X_i'i & X_i'X_i \end{bmatrix}^{-1} \begin{pmatrix} i'Y_i \\ X_i'Y_i \end{pmatrix}$$

$$i = n_1 + 1, n_1 + 2, \dots, n_1 + n_2$$

لنجد الموجهين  $\hat{\beta}^*$ ،  $\hat{\gamma}^*$  على التوالي:

$$\hat{\beta}^* = \begin{pmatrix} n_1 & \sum_{i=1}^{n_1} X_i \\ \sum_{i=1}^{n_1} X_i & \sum_{i=1}^{n_1} X_i^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum_{i=1}^{n_1} Y_i \\ \sum_{i=1}^{n_1} X_i Y_i \end{pmatrix} \dots (4.60)$$



$$\hat{\gamma}^* = \begin{pmatrix} n_2 & \sum_{i=n_1+1}^{n_1+n_2} X_i \\ \sum_{i=n_1+1}^{n_1+n_2} X_i & \sum_{i=n_1+1}^{n_1+n_2} X_i^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum_{i=n_1+1}^{n_1+n_2} Y_i \\ \sum_{i=n_1+1}^{n_1+n_2} X_i Y_i \end{pmatrix} \dots (4.61)$$

وباستعمال المعادلة (59.4) يمكننا الحصول على البواقي  $\hat{U}$  لكل من العينتين  $n_1$  و  $n_2$  أي  $n_1 + n_2$  ثم نتبع الخطوات الآتية لإختبار الفرضية:

$$H_0: \beta^* = \gamma^* \dots (4.62)$$

(a) نكون مجموع مربعات البواقي غير المقيدة URSS على النحو:

$$URSS = \hat{U}'\hat{U} = \hat{U}_1'\hat{U}_1 + \hat{U}_2'\hat{U}_2$$

حيث أن  $\hat{U}_1$  و  $\hat{U}_2$  هما بواقي المربعات الصغرى للعينتين  $n_1$ ،  $n_2$  على الترتيب.

(b) إن فرضية العدم والتي تدل على عدم وجود تغير هيكلية خلال الفترتين الزمنية المختلفتين، أو عدم إختلاف المعالم الهيكلية للنموذج خلال العينتين  $n_1$  و  $n_2$  هي كما في المعادلة (62.4). ونكتبها في صيغة قيود خطية  $R\beta = r$  كما يلي:

$$H_0: \begin{bmatrix} 1 & 0 & \vdots & -1 & 0 \\ 0 & 1 & \vdots & 0 & -1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \gamma_1 \\ \gamma_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$\begin{bmatrix} I & : & -I \end{bmatrix} \begin{bmatrix} \beta^* \\ \dots \\ \gamma^* \end{bmatrix} = \underline{0} \dots \dots (4.63)$$

$$R \quad \beta \quad = r$$

ويصبح النموذج المقيد على الشكل:

$$H_0: \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \beta^* + U \dots \dots (4.64)$$

أي

$$Y = X \beta + U$$

وبالرجوع للمعادلة (42.4) والمكتوبة على الشكل:

$$\frac{(R\hat{\beta} - r)' [R(X'X)^{-1}R']^{-1} (R\hat{\beta} - r) / m}{\hat{U}'\hat{U} / (n - k)} \sim F_{m, n-k}$$

حيث أن  $m$  هنا هي عدد القيود وتساوي 2 كما في (62.4). ومن المعادلة (37.4) لدينا مقدار المربعات الصغرى المقيدة:

$$\hat{\beta}_R = \hat{\beta} - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)$$

لتصبح لدينا العبارة:

$$R\hat{\beta} - r = - \left[ (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1} \right]^{-1} (\hat{\beta}_R - \hat{\beta})$$

وبتعويض العبارة الأخيرة، أعلاه بالمعادلة (42.4) نجد:

$$\frac{(\hat{\beta}_R - \hat{\beta})' X' X (\hat{\beta}_R - \hat{\beta}) / m}{\hat{U}' \hat{U} / (n - k)} \sim F_{m, n-k}^{(5)} \dots (4.65)$$

وهو الاختبار الخاص بالفرضية  $H_0$  بالمعادلة (63.4)، حيث أن  $n = n_1 + n_2$ . ولإجراء اختبار الفرضية  $H_0$  لدينا طريقتين، إما أن نستعمل مقدار المربعات الصغرى غير المقيدة بالمعادلة (59.4) والمصفوفة  $R$  والموجه  $r$  المعرفين بالمعادلة (63.4) لحساب الإحصاءة  $F$  المعرفة بالمعادلة (42.4). أو نحسب البواقي  $\hat{U}_R$  المقيدة من النموذج المقيد بالمعادلة (64.4) بواسطة المربعات الصغرى. ثم نعوض سواء في المعادلة (46.4) أو في المعادلة (65.4) أعلاه. وتكون الطريقة الثانية أسهل وأبسط من الأولى. حيث نعيد كتابة المعادلة (46.4) على الشكل:

$$\frac{(\hat{U}_R' \hat{U}_R - \hat{U}' \hat{U}) / m}{\hat{U}' \hat{U} / (n - k)} = \frac{(RRSS - URSS) / m}{\hat{U}' \hat{U} / (n - k)} \sim F_{m, n-k} \dots (4.66)$$

$$\hat{U}' \hat{U} = \hat{U}_1' \hat{U}_1 + \hat{U}_2' \hat{U}_2 \quad \text{حيث أن:}$$

وقد نكون في بعض الأحيان مهتمين بتجانس الميلين الحديين للإستهلاك في الدالة الكينزية المذكورة بالمعادلة (56.4). وتكون الفرضية الموجودة بالمعادلة (62.4) في شكل جديد كمايلي:

$$H_0: \beta_2 = \gamma_2 \dots (4.67)$$

<sup>5</sup> - تجدر الإشارة هنا إلى أن  $n = n_1 + n_2 = 12 + 11 = 23$ . كما أن عدد درجات الحرية في المقام هي  $n_1 + n_2 - 2k = 23 - 4 = 19$ . لأن عدد المعالم الهيكلية للنموذج غير المقيد تساوي 4. أما عدد القيود فهي  $m=2$ . ليصبح الاختبار في (65.4) و(66.4) هو على التوالي:

$$\frac{(\hat{\beta}_R - \hat{\beta})' X' X (\hat{\beta}_R - \hat{\beta}) / 2}{\hat{U}' \hat{U} / 19} \sim F_{2, 19}$$

$$\frac{(RRSS - URSS) / 2}{\hat{U}' \hat{U} / 19} \sim F_{2, 19}$$



حيث أن للمعلمتين  $\beta_1, \gamma_1$  مطلق الحرية في أخذ أي قيم مختلفة في الإحصاريين الموجودين بالمعادلة (56.4). إذ تخبرنا النظرية الكينزية بأن حجم مضاعف الدخل الوطني يعتمد على الميل الحدي للإستهلاك ( $\beta_2$  أو  $\gamma_2$ ) وليس على الحد الثابت ( $\gamma_1, \beta_1$ ) حيث أن هذا الأخير يشكل الاتفاق المستقل عند حساب الدخل التوازني. ومنه فإن  $H_0$  بالمعادلة (67.4) هي تعبير عن تماثل مضاعف الدخل في الفترتين الزمنيتين (1967-78). (1979-89). ومنه نكتب النموذج المقيد تبعاً لـ  $H_0$  في (67.4):

$$H_0: \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} i_1 & 0 & X_1 \\ 0 & i_2 & X_2 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \gamma_1 \\ \beta \end{bmatrix} + U \dots (4.68)$$

أما النموذج غير المقيد فهو:

$$H_A: \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} i_1 & X_1 & 0 & 0 \\ 0 & 0 & i_2 & X_2 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \gamma_1 \\ \gamma_2 \end{bmatrix} + U \dots (4.69)$$

حيث أن  $i_1$  هو متجه عمود  $1 \times n_1$  على الشكل:  $i_1' = (1 \dots 1)$  و  $i_2$  هو متجه عمود  $1 \times n_2$  كذلك  $i_2' = (1 \dots 1)$  هي  $X_1$  هي ملاحظات الدخل في الفترة (1967-78).  $X_2$  هي  $1 \times n_2$  ملاحظات الدخل للفترة (1979-89). وبتطبيق قانون المربعات الصغرى على النموذجين (68.4) و (69.4). نستطيع اختبار فرضية  $H_0$  وذلك بمقارنة RRSS من (68.4) مع URSS من (69.4). كما إعتدنا على ذلك من قبل. حيث نلاحظ أن النموذج (69.4) هو نفسه الموجود بالمعادلة (58.4). إذ أن:

$$\hat{U}_1' \hat{U}_1 = Y_1' Y_1 - \beta_1' X_1' Y_1$$

$$\hat{U}_2' \hat{U}_2 = Y_2' Y_2 - \beta_2' X_2' Y_2$$

لأن:

$$X_1 = [i_1 \quad \vdots \quad X_i] : i = 1, 2, \dots, n_1$$

$$X_2 = [i_2 \quad \vdots \quad X_i] : i = n_1 + 1, \dots, n_1 + n_2$$

لنجد أن:

$$URSS = \hat{U}'\hat{U} = \hat{U}'_1\hat{U}_1 + \hat{U}'_2\hat{U}_2$$

أما بالنسبة للنموذج المقيد بالمعادلة (68.4) فيكون النموذج على الشكل:

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = X_*\beta_0 + U : i = 1, 2, \dots, n_1 + n_2$$

حيث أن:

$$\beta'_0 = (\beta_1 \quad \gamma_1 \quad \beta)$$

$$X_* = \begin{pmatrix} i_1 & 0 & X_1 \\ 0 & i_2 & X_2 \end{pmatrix}$$

لنجد:

$$X'_*X_* = \begin{bmatrix} n_1 & 0 & i'_1X_1 \\ 0 & n_2 & i'_2X_2 \\ X'_1i_1 & X'_2i_2 & X'_1X_1 + X'_2X_2 \end{bmatrix}, \quad X'_*Y = \begin{bmatrix} i'_1Y_1 \\ i'_2Y_2 \\ X'_1Y_1 + X'_2Y_2 \end{bmatrix}$$

$$RRSS = \hat{U}'_*\hat{U}_* = Y'Y - Y'X_*(X'_*X_*)^{-1}X'_*Y$$

$$= Y'[I - X_*(X'_*X_*)^{-1}X'_*]Y = Y'M_*Y$$

ويكون الاختبار الإحصائي المناسب للفرضية  $H_0: \beta_2 = \gamma_2$  هو:

$$F = \frac{(RRSS - URSS) \cdot m}{URSS \cdot (n - 2k)} \sim F_{m, n-2k} \dots (4.70)$$

في مثالنا  $m = 1$ ,  $n = n_1 + n_2 = 23$ ,  $k = 2$ . لتصبح المعادلة (70.4):

$$F = \frac{(RRSS - URSS)/1}{URSS/19} \sim F_{1,19}$$

#### 2-4-4 اختبار التغير الهيكلي لـ k متغير مستقل:

ليكن لدينا النموذج الخطي العام  $Y = X\beta + U$ ، حيث لدينا الفترتين الزمنية (78-1967)، (89-1979). ونريد اختبار الفرضية  $H_0$  والقائلة بعدم تغير معالم النموذج خلال العينتين  $n_1 = 12$ ،  $n_2 = 11$  وتكون:

$$H_0: \beta_1 = \gamma_1, \beta_2 = \gamma_2, \dots, \beta_k = \gamma_k$$

ولنضع نموذجي العينتين على الشكل:

$$Y_1 = X_1\beta_1 + U_1 : i = 1, 2, \dots, n_1$$

$$Y_2 = X_2\beta_2 + U_2 : i = n_1 + 1, \dots, n_1 + n_2$$

حيث أن  $X_1$  هي  $n_1 \times k$  و  $X_2$  هي  $n_2 \times k$  لتكون الفرضية  $H_0$  هي:

$$H_0: \beta_1 = \beta_2 \dots (4.71)$$

ويكون النموذج غير المقيد على الشكل:

$$\begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \begin{bmatrix} X_1 & 0 \\ 0 & X_2 \end{bmatrix} \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} + U \dots (4.72)$$

ولنجزء المصفوفتين  $X_1$ ،  $X_2$  إلى الشكل:

$$X_1 = [i_1 \quad \vdots \quad X_{01}] , \quad X_2 = [i_2 \quad \vdots \quad X_{02}]$$

حيث أن  $i_1$  و  $i_2$  معرفتين من قبل. بينما  $X_{01}$  هي  $n_1 \times (k-1)$  و  $X_{02}$

هي  $n_2 \times (k-1)$  لتصبح المعادلة (72.4) على الشكل:



$$\begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \begin{bmatrix} i_1 & X_{01} & 0 & 0 \\ 0 & 0 & i_2 & X_{02} \end{bmatrix} \begin{bmatrix} c_1 \\ \beta_{01} \\ c_2 \\ \beta_{02} \end{bmatrix} + U \dots (4.73)$$

حيث أن  $c_1$  يمثل الحد الثابت الخاص بالعينة الأولى، كذلك  $c_2$  حد ثابت خاص بالعينة الثانية، أما  $\beta_{01}$  فهي  $1 \times (k-1)$  للعينة الأولى و  $\beta_{02}$  هي  $1 \times (k-1)$  للعينة الثانية. أما النموذج المقيد  $H_0: \beta_1 = \beta_2$  فهو:

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \beta + U$$

وبناء على تجزئة كل من  $X_1$  و  $X_2$  يصبح النموذج أعلاه على الشكل:

$$\begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} i_1 & X_{01} \\ i_2 & X_{02} \end{bmatrix} \beta + U \dots (4.74)$$

ويكون إختبار فرضية تساوي معالم الإنحدارين للفترتين المختلفتين بواسطة تقدير المعادلة غير المقيدة في (73.4) للحصول على URSS بدرجات حرية هي  $n_1 + n_2 - 2k$ . ومن ثم تقدير المعادلة المقيدة في (74.4) للحصول على RRSS بدرجات حرية هي  $n_1 + n_2 - k$ . ثم نكون الإختبار الإحصائي التالي:

$$F = \frac{(RRSS - URSS)/k}{URSS/(n_1 + n_2 - 2k)} \sim F_{k, n-2k} \dots (4.75)$$

وهو ما يسمى بإختبار التغير الهيكلي أو إختبار Chow. كما لما تكون  $n_2 < k$  فإن إنحدار الفترة الثانية ( $n_2$ ) يعطي بواقي معدومة ( $\hat{U}_2' \hat{U}_2 = 0$ ) لتصبح URSS على الشكل:  $URSS = \hat{U}' \hat{U} = \hat{U}_1' \hat{U}_1$  بدرجات حرية هي  $(n_1 - k)$ .

بينما النموذج المقيد بالمعادلة (74.4) يعطي نفس مجموع مربعات البواقي المقيدة RRSS بدرجات حرية هي  $n_1 + n_2 - k$  لتصبح المعادلة (75.4) على الشكل:

$$\frac{(RRSS - URSS)/n_2}{URSS/(n_1 - k)} = \frac{(RRSS - RSS_1)/n_2}{RSS_1/(n_1 - k)} =$$

$$\frac{(\hat{U}'_R \hat{U}_R - \hat{U}'_1 \hat{U}_1)/n_2}{\hat{U}'_1 \hat{U}_1/(n_1 - k)} \sim F_{n_2, n_1 - k} \dots (4.76)$$

وهو الاختبار المتكافئ مع ذلك الموجود بالمعادلة (54.4) والمسمى باختبار التنبؤ، ومنه نقول:

- (a) لما  $n_2 > k$  نفضل استعمال اختبار التغير الهيكلي بالمعادلة (75.4).  
 (b) لما  $n_2 \leq k$  نفضل استعمال اختبار التنبؤ بالمعادلة (76.4)  
 (c) وعادة ما يكون اختبار التغير الهيكلي أقوى من اختبار التنبؤ لأنه يستعمل كل المعلومات الموجودة بالعينتين في ثلاثة إحدارات منفصلة ومتتالية. بينما يستعمل اختبار التنبؤ إحدارين منفصلين فقط.

#### 5-4 المتغيرات الوهمية Dummy variables

تعاملنا لحد الآن مع المتغيرات المقاسة كمياً، مثل الإستهلاك، الدخل، الأسعار وغيرها. كل المتغيرات السالفة الذكر يمكن قياسها بالحجم أو بوحدة نقدية بينما هناك متغيرات إقتصادية أخرى لا يمكن قياسها بالطريقة المذكورة، وإنما بنسب مئوية مثل معدل الفائدة، البطالة، التضخم وغيرها. كما أننا قد نكون مهتمين في بعض الأحيان بمتغيرات إقتصادية لا تنتمي إلى المثالين المذكورين أعلاه، مثل دالة الإنتاج خلال المواسم الأربعة للسنة، أو دالة الإستهلاك خلال فترة الحرب وفترة السلم، أو إستهلاك لحم الخنزير في الدول المسيحية بالمقارنة مع الدول الإسلامية وغيرها. ويمكن تسمية هذه التصرفات الإقتصادية بالمتغيرات الكيفية أو النوعية **Qualitative Variables**، أي المتغيرات التي لا تحتوي على ميزان طبيعي للقياس.



ولنأخذ أمثلة عن ذلك. ففي تحليل السلاسل الزمنية لدالة الإستهلاك لأفراد المجتمع الجزائري، يمكن أن ننظر للإتفاق الإستهلاكي بأنه لايعتمد على الدخل الفردي المتاح فقط. بل يمكن أن يعتمد على الظروف التي تمر بها البلاد. هل هي فترة رخاء إقتصادي أم كساد إقتصادي؟ - هل الفترة المدروسة هي فترة إقتصاد مخطط أو إقتصاد مفتوح لحرية المنافسة الدولية والمحلية. حيث خلال فترة فرض سياسة تجارية وحماية صارمة على الواردات من السلع والخدمات الأجنبية، نتوقع أن يكون مستوى الإستهلاك منخفضا عن فترة سياسة السوق المفتوحة والحرية مهما كان مستوى دخل الأفراد.

وفي دراسة تحليلية لبيانات مقطعية نتوقع كذلك بأن يكون نوع ومستوى إستهلاك عوائل المدينة مختلفا عن نوع ومستوى إستهلاك عوائل الريف مهما كان مستوى دخل الأفراد كذلك، لأن التصرف الإستهلاكي يختلف لدى النوعين من أفراد المجتمع، وبسبب كل هذه الفروقات يمكن إدخال هذه المتغيرات الإقتصادية وغير الإقتصادية في شكل متغيرات وهمية لنمذجة الآثار التي نريد إختبارها.

#### 4-5-1 تغير الحد الثابت:

لنأخذ دالة الإستهلاك الكينزية، ونفترض مبدئيا، أن متغيرنا النوعي (الوهمي) يؤثر على الحد الثابت ولايؤثر على ميل العلاقة (الميل الحدي للإستهلاك) ولنأخذ مثالا عن أثر سياسة فتح السوق الوطنية لبعض المنتجات الأجنبية بداية من سنة 1979 في تغير مستوى الإستهلاك لدى أفراد المجتمع الجزائري. فإذا كتبنا معادلة الإستهلاك على الشكل:

$$Y_t = \beta_1 + \beta_2 X_t + u_t \quad ; \quad t = 1967, \dots, 1989.$$

حيث أن تغير الإستهلاك الفردي  $Y_t$  في الفترة  $t$  محدد بواسطة تغير مستوى الدخل الفردي  $X_t$  في نفس الوقت. ولنفرض أن فرض سياسة تعويم السوق الوطنية بالمنتجات الأجنبية سوف تزيد من كمية الإستهلاك ولكنها لا تغير من أثر



الدخل  $X_t$  في الإستهلاك  $Y_t$ . أي أن تطبيق هذه السياسة لا يؤثر على  $\beta_2$ . ونكتب دالة الإستهلاك من جديد على الشكل:

$$I: Y_t = \beta_1 + \beta_2 X_t + \beta_3 D_t + u_t \dots (4.77)$$

$$t = 1967, \dots, 89.$$

$$D_t = \begin{cases} 1 & \text{فترة تطبيق السياسة} \\ 0 & \text{غير ذلك} \end{cases} \dots (4.77)'$$

نسمي  $D_t$  بالمتغير الوهمي (أو المتغير المؤشر). ويكون شرح المعادلة هو أنه خلال الفترات التي لا تنطبق فيها سياسة التعويم ( $D_t = 0$ ) تكون العلاقة مابين الإستهلاك والدخل كمايلي:

$$Y_t = \beta_1 + \beta_2 X_t + u_t : t = 1967, \dots, 1978 \dots (4.78)$$

أما خلال فترات إدخال هذه السياسة الإقتصادية ( $D_t = 1$ ) تكون المعادلة كمايلي:

$$Y_t = (\beta_1 + \beta_3) + \beta_2 X_t + u_t : t = 1979, \dots, 89 \dots (4.79)$$

حيث أن الزيادة حدثت بسبب تغير القيود وليس بسبب زيادة الدخل ومنه نتوقع أن تكون قيمة  $\beta_3$  موجبة. ونقدر المعالم بنفس الطريقة المعروفة (المربعات الصغرى العادية)، كأن  $D_t$  هو متغير مستمر. ونلاحظ أنه بالإضافة إلى فرضية تساوي الميلين الحديين للإستهلاك في الإنحدارين (78.4) و (79.4)، يجب أن نفترض بأن النموذج (77.4) هو معادلة في شكل مختصر وعلى الخصوص أن  $D_t$  هو متغير خارجي exogenous، وهذا يعني أن مستوى إستهلاك الأفراد  $Y_t$  لا يؤثر على قرار المخطط أو مسؤول الحكومة في إتخاذ قرار تعويم السوق الوطنية أم لا. كما نفترض كذلك بأن أثر سياسة التعويم على الإستهلاك تبقى ثابتة خلال كل مدة

القرار المتخذ أي خلال (1979-1989). ولشرح المعادلات المقدرة مع المتغيرات الوهمية، نفترض النتائج التالية:

$$\hat{Y}_t = 12 + 0,9X_t + 8D_t \dots (4.80)$$

$$S.E \quad (2) \quad (0,1) \quad (2,0)$$


ومن القيمة  $SE(\hat{\beta}_3) = 2$  نلاحظ أن الفرضية  $H_0: \beta_3 = 0$  مرفوضة. ونستخلص أنه خلال فترة تطبيق سياسة التعويم بالمنتجات الأجنبية كان الأثر إيجابيا على تغير الإستهلاك. إن المعادلة التقديرية للإستهلاك هي:

$$\hat{Y}_t = 12 + 0,9X_t : t = 67, \dots 78 \dots (4.81) \quad \text{عدم تطبيق}$$

السياسة

$$\hat{Y}_t = 20 + 0,9X_t : t = 79, \dots 89 \quad \text{تطبيق السياسة}$$

ونوضح سياسة تعويم السوق الوطنية في انشك (1.4) ادتالي:



شكل (1.4)

#### 2-5-4 إختلاف الميل وعدم تغير الحد الثابت:

لنأخذ الآن الحالة المتعددة، حيث نفترض بأن سياسة التعويم تؤثر على الميل الحدي للإستهلاك عوضا عن الحد الثابت. ونكتب في هذه الحالة معادلة الإتحدار لدالة الإستهلاك على النحو:

$$\text{II: } Y_t = \beta_1 + \beta_2 X_t + \beta_4 (X_t D_t) + u_t \dots (4.82)$$

ويسمى  $D_t$  هنا بالمتغير الوهمي المتعدد، ويبقى معرّفا كما في (77.4).  
ويصبح شرح المعادلة (82.4) هو أنه من خلال الفترات التي لا تنطبق فيها سياسة التعويم ( $D_t = 0$ ) تكون العلاقة بين  $X_t$  و  $Y_t$  كما في (78.4). بينما خلال الفترة التي تنطبق فيها هذه السياسة (1979-1989)،  $D_t = 1$ ، فهي:


$$Y_t = \beta_1 + (\beta_2 + \beta_4) X_t + u_t \dots (4.83)$$

مثلا سبق، نقدر المعادلة (82.4) بواسطة المربعات الصغرى وكأن  $D_t$  متغير مستمر. كما أننا نأخذ العبارة  $X_t D_t$  كأنها متغير منفصل حيث يأخذ القيم التالية:

$$X_t D_t = \begin{cases} X_t & : D_t = 1 \\ 0 & : D_t = 0 \end{cases}$$

حيث نتوقع أن يكون  $\beta_4$  موجبا. وتكون المعادلة التقديرية للإستهلاك مبيّنة في الشكل (2.4) أدناه:





شكل (2.4)

#### 3-5-4 الحالة التوفيقية

لنوفق الآن الحالتين السابقتين في نفس المعادلة. ونفرض أن كلا من الحد الثابت (حد الكفاف) والميل الحدي للإستهلاك للعلاقة يكونان مختلفين خلال الفترتين الزمنية (78-67)، (79-89). أي فترة تطبيق سياسة التعويم وفترة عدم تطبيقها. ثم نكتب معادلتنا المناسبة لهذه الحالة على الشكل:

$$\text{III: } Y_t = \beta_1 + \beta_2 X_t + \beta_3 D_t + \beta_4 (X_t D_t) + u_t \dots (4.84)$$


حيث لما نكون خارج فترة تطبيق السياسة (78-67)،  $D_t = 0$ . فإن المعادلة (84.4) تصبح في صيغة النموذج (78.4). بينما خلال فترة تطبيق السياسة،  $D_t = 1$ . فإن النموذج (84.4) يأخذ الشكل:

$$Y_t = (\beta_1 + \beta_3) + (\beta_2 + \beta_4)X_t + u_t : t = 79, \dots, 89; \dots (4.85)$$

وبتطبيق قانون المربعات الصغرى على المعادلة (84.4)، خلال فترة تطبيق السياسة نحصل على:

$$\hat{Y}_t = (\hat{\beta}_1 + \hat{\beta}_3) + (\hat{\beta}_2 + \hat{\beta}_4)X_t \dots (4.86)$$

ونتوقع من  $\hat{\beta}_3$  و  $\hat{\beta}_4$  أن يكونا موجبين. وتظهر العلاقة مابين الفترتين كما في الشكل (3.4):



شكل (3.4)

ومادام كنا قد افترضنا بأن كلا من الحد الثابت والميل مختلفان خلال الفترتين المذكورتين، فإننا نستطيع فصل العينة ( $n=23$ ) إلى عينتين مختلفتين، تحتوي الأولى  $n_1 = 12$  على الفترة (67-78)، والثانية  $n_2 = 11$  على الفترة (79-89)، لنكون في الأخير إتحارين مختلفين كمايلي:

$$\hat{Y}_t = \hat{\alpha}_1 + \hat{\alpha}_2 X_t : D_t = 0 \quad \dots (4.87)$$

$$\hat{Y}_t = \hat{\gamma}_1 + \hat{\gamma}_2 X_t : D_t = 1$$

ومنه نلاحظ أن الطريقتين تعطيان مقدرات متكافئة حيث:

$$\begin{array}{l} D_t = 0 \\ n_1 = 12 \end{array} \quad \left[ \begin{array}{l} \hat{\alpha}_1 = \hat{\beta}_1 \\ \hat{\alpha}_2 = \hat{\beta}_2 \end{array} \right.$$

$$\begin{array}{l} D_t = 1 \\ n_2 = 11 \end{array} \quad \left[ \begin{array}{l} \hat{\gamma}_1 = \hat{\beta}_1 + \hat{\beta}_3 \\ \hat{\gamma}_2 = \hat{\beta}_2 + \hat{\beta}_4 \end{array} \right.$$

لنجد أن:

$$\hat{\beta}_3 = \hat{\gamma}_1 - \hat{\alpha}_1$$

$$\hat{\beta}_4 = \hat{\gamma}_2 - \hat{\alpha}_2$$

لتصبح المعادلة التقديرية للنموذج (84.4) على الشكل:

$$\hat{Y}_t = \hat{\alpha}_1 + \hat{\alpha}_2 X_t + (\hat{\gamma}_1 - \hat{\alpha}_1) D_t + (\hat{\gamma}_2 - \hat{\alpha}_2) (X_t D_t) \dots (4.88)$$

وتعتبر المعادلة (88.4) متماثلة مع حاصل ضرب المعادلة الثانية (87.4) بواسطة  $D_t$ ، مضافا إليها حاصل ضرب المعادلة الأولى (87.4) بواسطة  $(1 - D_t)$  أي:

$$(1 - D_t) \quad \left| \quad \hat{Y}_t = \hat{\alpha}_1 + \hat{\alpha}_2 X_t : t = 67, \dots, 78 \right.$$

$$(D_t) \quad \left| \quad \hat{Y}_t = \hat{\gamma}_1 + \hat{\gamma}_2 X_t : t = 79, \dots, 89 \right.$$

$$\hat{Y}_t = \hat{\alpha}_1 + \hat{\alpha}_2 X_t + (\hat{\gamma}_1 - \hat{\alpha}_1) D_t + (\hat{\gamma}_2 - \hat{\alpha}_2) (X_t D_t)$$

وإذا كنا مهتمين باختبار التحركات Shifts في خط الإنحدار والموجودة بالشكل (3.4)، يكون تقدير العينة الكلية  $n=23$  هو الطريقة الصحيحة مادامت تعطي مقدرات مباشرة لتحرك الحد الثابت  $\beta_3$ ، وتحرك الميل  $\beta_4$ . أما إذا كنا مهتمين بالمعادلتين



الخاصتين بالفترتين المختلفتين، يكون تقدير العينتين المنفصلتين  $n_1 = 12$ ،  $n_2 = 11$  هو الأحسن، وتبقى نتائجنا المتحصل عليها، صحيحة لما نوسع هذه الطريقة إلى نموذج يحتوي على عدة متغيرات مستقلة. وإذا أخذنا الحالات الثلاثة السابقة الذكر في شكل مصفوفات تكون على الشكل التالي:

$$I: \begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \begin{bmatrix} i_1 & X_1 & 0 \\ i_2 & X_2 & i_2 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix} + U \dots (4.89)$$

حيث أن  $i_1$  هي  $n_1 \times 1$  و  $i_2$  هي  $n_2 \times 1$  لعناصر الواحد. أما  $X_1$  و  $X_2$  فتشير إلى فترة عدم تطبيق السياسة (67-78) وفترة تطبيق السياسة (79-89) على الترتيب. أما النموذج الثاني بالمعادلة (82.4) فيكتب:

$$II: \begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \begin{bmatrix} i_1 & X_1 & 0 \\ i_2 & X_2 & X_2 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_4 \end{bmatrix} + U \dots (4.90)$$

أما الحالة التوفيقية فتعطي:

$$III: \begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \begin{bmatrix} i_1 & X_1 & 0 & 0 \\ i_2 & X_2 & i_2 & X_2 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \end{bmatrix} + U \dots (4.91)$$

وبتقدير النماذج (89.4)، (90.4)، (91.4) نحصل على نفس النتائج المحصلة في الأشكال (1.4)، (2.4)، (3.4) على الترتيب.

#### 4-5-4 المتغيرات الوهمية كمتغيرات مستقلة وحيدة:

بالرغم من أن المعادلات المحتوية على المتغيرات الوهمية فقط صعبة التقدير، فإن إهتماما بسيطا من طرفنا حول هذه المعادلات يساعدنا على فهم وشرح معالم المتغيرات الوهمية في المعادلات التي تحتوي أيضا على متغيرات وهمية. ولنعتبر الحالة البسيطة التي تحتوي على متغير مستقل واحد (متغير وهمي واحد). حيث نفرض أنه لدينا عينة بيانات مقطعية لأفراد بعضهم له مستوى البكالوريا أو مايعادلها، والبعض الآخر ليس له هذا المستوى. ولنعرف  $Y_i$  كمعدل شهري لمدخل الفرد  $i$ ، ونعرف:

$$D_i = \begin{cases} 1 & \text{إذا كان الفرد } i \text{ له مستوى البكالوريا} \\ 0 & \text{غير ذلك} \end{cases}$$

ولنعتبر معادلة الانحدار التالية:

$$Y_i = \beta_1 + \beta_2 D_i + u_i \dots (4.92)$$

ولتكن  $\bar{Y}$  هي وسط المداخل الشهرية لأفراد العينة ذات مستوى بكالوريا ومايعادلها أما  $\bar{Y}_0$  فهي وسط المداخل الشهرية لأفراد العينة غير المتحصلين على البكالوريا. لتكون مقدرات المربعات الصغرى هي:

$$\hat{\beta}_1 = \bar{Y}_0 \dots D_i = 0$$

$$\hat{\beta}_2 = \bar{Y} - \bar{Y}_0 \dots D_i = 1$$

حيث نلاحظ أن معامل المتغير الوهمي هو ببساطة عبارة عن الفرق في وسط المداخل بين المجموعتين من الأفراد. أما إذا اعتبرنا عدة عوامل أخرى مثل ذوي الشهادات الجامعية، ذوي مستوى البكالوريا، وذوي شهادات أقل من البكالوريا، فإنه يمكننا إظهار أثر المداخل الشهرية بوضع متغيرين وهميين:

$$D_{1i} = \begin{cases} 1 & \text{إذا كان الفرد } i \text{ له البكالوريا كأعلى مستوى غير ذلك} \\ 0 & \end{cases}$$

$$D_{2i} = \begin{cases} 1 & \text{إذا كان الفرد } i \text{ له شهادة جامعية غير ذلك} \\ 0 & \end{cases}$$

- ولنعتبر الإتحاد التالي:

$$Y_i = \beta_1 + \beta_2 D_{1i} + \beta_3 D_{2i} + u_i \dots (4.93)$$

$$Y = D \cdot \beta + U$$

حيث يكون موجه المصفوفة على الشكل:  $D = [i \quad D_1 \quad D_2]$  وموجه المعالم هو:  $\beta' = [\beta_1 \quad \beta_2 \quad \beta_3]$

ولتكون مصفوفة البيانات  $D$  على الشكل:

$$D = \begin{bmatrix} i_0 & 0 & 0 \\ i_1 & D_1 & 0 \\ i_2 & 0 & D_2 \end{bmatrix} = \begin{bmatrix} i_0 & 0 & 0 \\ i_1 & i_1 & 0 \\ i_2 & 0 & i_2 \end{bmatrix}$$

لأن  $D$  تأخذ القيمة واحد أو الصفر. كما أن  $i$  هو موجه عمود من الواحد ويأخذ الشكل:

$$i = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ \vdots \\ 1 \end{bmatrix} = \begin{bmatrix} i_0 \\ \dots \\ i_1 \\ \dots \\ i_2 \end{bmatrix}$$

ثم إن  $i_0$  تناسب عينة الأفراد  $n_1$  بمستوى دون البكالوريا. أما  $i_1$  فتناسب عينة الأفراد  $n_2$  مستوى البكالوريا. بينما  $n_3$  بمستوى جامعي. وتكون:



$$D'D = \begin{bmatrix} n & n_2 & n_3 \\ n_2 & n_2 & 0 \\ n_3 & 0 & n_3 \end{bmatrix}, \quad D'Y = \begin{bmatrix} \sum Y_0 + \sum Y_1 + \sum Y_2 \\ \sum Y_1 \\ \sum Y_2 \end{bmatrix}$$

حيث أن:  $Y_0$  هي المداخل الشهرية لعينة الأفراد دون مستوى البكالوريا

$Y_1$  هي المداخل الشهرية لعينة الأفراد بمستوى البكالوريا

$Y_2$  هي المداخل الشهرية لعينة الأفراد بمستوى جامعي.

وإذا كانت  $\bar{Y}_0, \bar{Y}_1, \bar{Y}_2$  هي أوساط القيم  $Y_0, Y_1, Y_2$  على الترتيب، فإن

تطبيق قانون المربعات الصغرى على النموذج (93.4) يعطي النتائج التالية:

$$\hat{\beta} = \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \hat{\beta}_3 \end{pmatrix} = \begin{pmatrix} \bar{Y}_0 \\ \bar{Y}_1 - \bar{Y}_0 \\ \bar{Y}_2 - \bar{Y}_0 \end{pmatrix} \dots (4.94)$$

#### 4-5-5 المتغير الوهمي كمتغير تابع:

لنعتبر المعادلة التالية:

$$Y_i = \beta_1 + \beta_2 X_i + u_i \dots (4.95)$$

حيث أن  $X_i$  هي دخل العائلة  $i$ ،  $Y_i$  ملكية العائلة  $i$  لدفتر إيداع.

$$Y_i = \begin{cases} 1 & \text{لما العائلة } i \text{ تملك دفتر إيداع} \\ 0 & \text{العائلة } i \text{ لا تملك دفتر إيداع} \end{cases}$$

في هذه الحالة نواجه عدة مشاكل عند تطبيق قانون المربعات الصغرى ومنها:

(a) أن الأخطاء  $u_i$  لا تتوزع طبيعيا ومعطاة بالعلاقة:

$$u_i = Y_i - \beta_1 - \beta_2 X_i$$

حيث أن  $Y_i$  تأخذ فقط القيمتين واحد وصفر. ومنه من أجل أية قيمة لـ  $X_i$ . فإن  $u_i$  تساوي المقدارين التاليين فقط:

$$u_i = \begin{cases} 1 - \beta_1 - \beta_2 X_i & : Y_i = 1 \\ -\beta_1 - \beta_2 X_i & : Y_i = 0 \end{cases}$$

وبالتالي نقول، بمعرفة قيم  $X_i$  و  $u_i$  يكون لهذه الأخيرة التوزيع الإحتمالي المتقطع التالي:

$u_i$	$pr(u_i)$
$1 - \beta_1 - \beta_2 X_i$	$p_i$
$-\beta_1 - \beta_2 X_i$	$1 - p_i$

حيث أن  $p_i$  هي إحتمال إمتلاك العائلة  $i$  لدفتر إدار بمعرفة دخلها  $X_i$ . ومنه نستنتج بأن توزيع  $u_i$  بمعرفة  $X_i$  يكون غير طبيعي.

(b) المشكل الثاني هو مسألة الشرح والتنبؤ. إذ تأخذ  $Y_i$  القيمة واحد بإحتمال  $p_i$  والقيمة صفر بإحتمال  $(1 - p_i)$ . ومنه نقول  $E(Y_i) = p_i$ . لتكون معادلتنا الخطية  $E(Y_i) = \beta_1 + \beta_2 X_i$  مشروحة كمعادلة إحتمالية ومجال قيمتها هو  $[0, 1]$ .

وتكون مقدرتها هي  $\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_i$  والتي يمكن أن تأخذ قيما خارج المجال  $[0, 1]$  لأنها غير محددة.

(c) إن الأخطاء  $u_i$  سوف تكون لها تباينات غير متجانسة. حيث من (b) أعلاه لدينا:

$$p_i = E(Y_i) = \beta_1 + \beta_2 X_i$$



وتكون لها قيمتين ممكنتين. وبمعرفة  $X_i$ ، فإن تباينات الأخطاء سوف تعتمد على  $X_i$ . وبسبب هذه المشاكل لا يمكن تطبيق قانون المربعات الصغرى العادية، على هذا النموذج الخطي. فإما أن نجري بعض التغييرات أو نختار طريقة أخرى للتقدير. وسوف نتطرق لها بالتفصيل عند مناقشتنا لموضوع المتغيرات التابعة والكيفية في فصول أخرى.

#### 4-5-6 استعمال المتغيرات الوهمية للتعديل الموسمي:

تلعب المتغيرات الوهمية دورا مهما في مشاكل التعديل الموسمي. إذ أن عدة بيانات إقتصادية للسلاسل الزمنية تبين تذبذبات موسمية. فمثلا الإنتاج الصناعي لعدة مؤسسات إنتاجية ينخفض عادة في الربع الثالث من السنة بسبب أخذ العمال لعطلهم الصيفي. كما أن إستهلاك أنواع معينة من العصير ينخفض في الربع الأول من السنة في البلدان المتوسطية كالجزائر، بسبب انخفاض درجات الحرارة. وهناك طريقتان أساسيتان للأخذ بعين الاعتبار هذه التذبذبات الموسمية عند تقدير العلاقات الإقتصادية من هذا النوع. تتمثل الطريقة الأولى في إزالة العامل الموسمي للبيانات Deseasonalising data قبل تقديرها. أما الطريقة الثانية فهي استعمال متغيرات وهمية خاصة خلال التقدير. ونظرا للعيوب التي تنتج عن الطريقة الأولى<sup>(6)</sup>، فإن الطريقة الثانية (إدخال متغيرات وهمية) هي الحل الأمثل لتحاشي عيوب الطريقة الأولى. فإذا كانت لدينا المتغيرات الوهمية التالية:

$$D_{it} = \begin{cases} 1 & \text{إذا كانت الملاحظة } t \text{ تنتمي إلى الربع } i \\ 0 & \text{غير ذلك} \end{cases}$$

ومنه فإن المتغيرات الأربعة ( $D_{1t}$ ,  $D_{2t}$ ,  $D_{3t}$ ,  $D_{4t}$ ) تضاف للمعادلة الخاصة

6- أنظر:

Mark.B Stewart and K.F Wallis

"Introductory Econometrics". Basil Black-Well publishing OXFORD. Page 179. 1981



بالإنحدار المدروس. فمثلا عند تقدير دالة الإستهلاك البسيطة وأخذ التذبذبات الموسمية بعين الاعتبار، يمكن أن نقدر النموذج:

$$Y_t = \beta_1 + \beta_2 X_t + \gamma_1 D_{1t} + \gamma_2 D_{2t} + \gamma_3 D_{3t} + \gamma_4 D_{4t} + u_t \dots (4.96)$$

إن إدخال المتغيرات الوهمية الأربعة بهذه الطريقة يعني أننا افترضنا بأن التذبذبات الموسمية في الإستهلاك تؤثر فقط على الحد الثابت في العلاقة المدروسة، وهي الحالة المذكورة بالشكل (1.4). حيث نفرض، مثلا، أن الميل الحدي للإستهلاك  $\beta_2$  هو نفسه عبر المواسم. أما إذا سمحنا لمكونات الموسم  $D_{it}$  بالتأثير على الميل الحدي للإستهلاك، فيجب علينا إدخال المتغيرات الوهمية المتعددة والموجودة بالمعادلة (82.4) والمبينة بالشكل (2.4)، ولكن تكون هنا بشكل معقد أكثر.

إن السؤال المطروح هنا هو كيف تكون المقدرات المحصلة من إدخال المتغيرات الوهمية الموسمية بالمقارنة مع تلك المحصلة من إزالة عنصر الموسم في البيانات أو البيانات المعدلة. ولنفرض أننا حصلنا على السلسلة "المعدلة الموسم" لكل من الإستهلاك  $Y_t$  والدخل  $X_t$  ونسميها  $\tilde{Y}_t$  و  $\tilde{X}_t$  على الترتيب. ومن ثم نقدر الإنحدار التالي:

$$\tilde{Y}_t = \alpha_1 + \alpha_2 \tilde{X}_t + \varepsilon_t \dots (4.97)$$

ثم نتساءل كيف تكون قيمة  $\hat{\alpha}_2$  بالمقارنة مع قيمة  $\hat{\beta}_2$  بالمعادلة (96.4). حيث من خصائص الإنحدار الجزئي بالمعادلة (73.3)، بالفصل الثالث، يمكن القول بأنه إذا كانت البيانات "المعدلة الموسم" محصلة من تحديرها في المتغيرات الوهمية الموسمية  $D_{it}$ ، فإن المعادلتين (96.4) و (97.4) تعطيان النتيجة  $\hat{\beta}_2 = \hat{\alpha}_2$  أي نفس الميل الحدي للإستهلاك. ولتوضيح ذلك، نعتبر المعادلة (96.4) في شكل مصفوفات على النحو:

$$Y = X\beta + D\gamma + U \dots (4.98)$$

حيث أن:

$$D = [D_{1t}, D_{2t}, D_{3t}, D_{4t}] \quad , \quad X = [\begin{matrix} 1 \\ X_t \end{matrix}]$$

$$t = 1, 2, \dots, n$$

ومنه يكون النموذج التقديري للمعادلة أعلاه هو:

$$Y = X\hat{\beta} + D\hat{\gamma} + e....(4.99)$$

وهو إنحدار قيم  $Y$  غير المعدلة في قيم  $X$  غير المعدلة ومجموعة المتغيرات الوهمية والموسمية  $D_{it}$ . فإذا كتبنا النموذج التقديري أعلاه في صيغته المجزأة التالية:

$$Y = \begin{bmatrix} X & D \end{bmatrix} \begin{bmatrix} \hat{\beta} \\ \hat{\gamma} \end{bmatrix} + e = Z\hat{\delta} + e$$

ليكون موجه المقدرات  $\hat{\delta}$  على النحو:

$$\hat{\delta} = \begin{bmatrix} \hat{\beta} \\ \hat{\gamma} \end{bmatrix} = (Z'Z)^{-1} Z'Y = \begin{bmatrix} X'X & X'D \\ D'X & D'D \end{bmatrix}^{-1} \begin{bmatrix} X'Y \\ D'Y \end{bmatrix}....(4.100)$$

وبتطبيق القانون العام لمعكوس المصفوفة، يكون العنصر الأول في المصفوفة  $(Z'Z)^{-1}$  هو على الشكل:

$$(X'X - X'D(D'D)^{-1}D'X)^{-1} = (X'M_D X)^{-1}$$

$$M_D = I - D(D'D)^{-1}D'$$

وتكون المصفوفة  $M_D$  متناظرة وخاملة لتتحقق الخاصية  $M_D D = 0$ . أما العنصر الموجود بالسطر الأول والعمود الثاني للمصفوفة  $(Z'Z)^{-1}$  فهو:  $-(X'M_D X)^{-1} X'D(D'D)^{-1}$ . ليكون موجه المقدرات  $\hat{\beta}$  هو:

$$\hat{\beta} = (X'M_D X)^{-1} X'Y - (X'M_D X)^{-1} X'D(D'D)^{-1} D'Y$$

$$\hat{\beta} = (X'M_D X)^{-1} X'M_D Y....(4.101)$$

لنعرف الآن المتغيرات المعدلة (المحولة) على الشكل:



$$\tilde{Y} = M_D Y, \quad \tilde{X} = M_D X \dots (4.102)$$

إن  $\tilde{Y}$  هو موجه بواقي إنحدار المربعات الصغرى والمحصل من تحديد  $Y$  في المتغيرات الوهمية والموسمية  $D_{it}$  أي:

$$\tilde{Y} = Y - D\hat{\theta} = Y - D(D'D)^{-1}D'Y = M_D Y$$

$$\hat{\theta} = (D'D)^{-1}D'Y$$

كما أن كل عمود من المصفوفة  $\tilde{X}$  هو عبارة عن موجه بواقي مربعات صغرى محصلة من تحديد المتغير  $X$  في  $D$ . ومنه نقول إذا حددنا  $\tilde{Y}$  "المعدلة" في  $\tilde{X}$  "المعدلة" كما في المعادلة (97.4) فإن موجه المقدرات المناسب لذلك هو:

$$\hat{\theta} = (\tilde{X}'\tilde{X})^{-1}\tilde{X}'\tilde{Y} = (X'M_D X)^{-1}X'M_D Y = \hat{\beta}$$

ومنه نصل إلى النتيجة المحصلة في الفصل الثالث بالمعادلة (79.3). ونقول أنه إذا جزئنا المتغيرات المستقلة في أي إنحدار إلى كتلتين من المتغيرات المستقلة مثل  $[X : D]$ ، فإن مقدرات المعالم لكتلة المتغيرات المستقلة هي نفسها، سواء، حددنا  $Y$  في كل من  $X$  و  $D$  أو بتعديل  $Y$  و  $X$ ، وتحديد كل منهما في  $D$  على إنفراد، ثم إذا حسبنا الإتحارين التقديرين:

$$Y = X\hat{\beta} + D\hat{\gamma} + e$$

$$\tilde{Y} = \tilde{X}\hat{\theta} + v$$

$$\hat{\beta} = \hat{\theta} \dots (4.103) \quad \text{فإن:}$$

كما يستخلص الباحث (7) Lovell نتيجتين مهمتين بالإضافة إلى النتيجة الموجودة بالمعادلة (103.4) وهي أن تحديد  $Y$  أولا في  $\tilde{X}$ ، وثانيا في كل من  $\tilde{X}$  و  $D$  تعطيان موجهي مقدرات مساويين للموجهين المحصل عليها بالمعادلة (103.4)



حيث أن تحديد المعادلتين:

$$Y = \tilde{X}\hat{\alpha}_1 + V_1 \dots (4.104)$$

$$Y = \tilde{X}\hat{\alpha}_2 + D\hat{\gamma}_2 + V_2 \dots (4.105)$$

حيث أن  $V_1$  ،  $V_2$  هي بواقي الإندار . فمن المعادلة (104.4) نجد:

$$\hat{\alpha}_1 = (X'M_D X)^{-1} X'M_D Y = \hat{\beta}$$

أما من المعادلة (105.4) نجد:

$$\begin{bmatrix} \hat{\alpha}_2 \\ \hat{\gamma}_2 \end{bmatrix} = \begin{bmatrix} X'M_D X & X'M_D D \\ D'M_D X & D'D \end{bmatrix}^{-1} \begin{bmatrix} X'M_D Y \\ D'Y \end{bmatrix}$$

$$= \begin{bmatrix} (X'M_D X)^{-1} X'M_D Y \\ (D'D)^{-1} D'Y \end{bmatrix} = \begin{bmatrix} \hat{\beta} \\ \hat{\gamma}_2 \end{bmatrix}$$

لأن  $M_D D = 0$

#### 6-4 التعدد الخطي Multicollinearity

إن الشرط الأهم لتطبيقات المربعات الصغرى هو أن المتغيرات المستقلة ليست مرتبطة خطيا تماما أي أن  $r_{X_i X_j}^{(8)} \neq 0$  ، أو لا توجد أية علاقة خطية صحيحة فيما بين متغيرين مستقلين أو أكثر. كما أن الفرضية الخاصة بالمصفوفة  $X$  بالنسبة للنموذج الخطي العام بالمعادلة (26.3) تتطلب أن تكون رتبة  $X$  مساوية لـ  $k$ ، أما إذا كان على الأقل هناك عمودين من  $X$  مرتبطين خطيا، تصبح  $\text{Rank}(X) < k$ . في هذه الحالة يطرح مشكل التعدد الخطي. يستعمل مفهوم التعدد الخطي للإشارة إلى وجود العلاقات الخطية فيما بين المتغيرات المستقلة. فإذا

<sup>8</sup> - إن  $r_{X_i X_j}$  هو معامل الارتباط البسيط ما بين المتغيرين المستقلين  $X_i$  و  $X_j$  حيث أن  $i \neq j$

وكذلك  $i, j = 1, 2, \dots, k$

كان الارتباط من النوع  $r_{x_i x_j} = 1$  ، تصبح المعالم غير محددة، ويصبح من المستحيل الحصول على قيم عددية لكل معلمة على أفراد. ومنه يتعذر علينا تطبيق قاتون المربعات الصغرى العادية. أما إذا كانت المتغيرات المستقلة غير مرتبطة أصلا فيما بينها،  $r_{x_i x_j} = 0$  ، تكون المتغيرات المعنية متعامدة أي  $\frac{1}{n} \sum x_i x_j = 0$  ، ومنه لا يوجد أي مشكل يذكر في تقدير المعالم.

ويشير Goldberger<sup>(9)</sup> بأنه في حالة تعامد المتغيرات المستقلة، لا تحتاج إلى إجراء تحليل متعدد. إذ أن كل معلمة مقدرة  $\hat{\beta}_j$  يمكن أن تقدر بواسطة إنحدار بسيط لـ Y في المحدر المناسب أي  $Y=f(X_j)$ .

لقد استعملت كلمة "التعدد الخطي" لأول مرة في أدبيات القياس الإقتصادي من طرف الباحث Ragnar Fisher سنة 1934 في كتابه تحت عنوان التحليل التوافدي أي Confluence Analysis.

عمليا، لا نتصادف مع الحالتين المذكورتين أعلاه (الارتباط التام، أو التعامد). ففي أغلب الحالات، تكون هناك درجة معينة من الارتباط فيما بين المتغيرات المستقلة بسبب تبعية التصرفات الإقتصادية لبعضها البعض عبر الزمن. ويكون في هذه الحالة لمعامل الارتباط البسيط  $r$  ، مابين كل زوج من المتغيرات المستقلة، قيمة محصورة مابين الصفر والواحد. ويمكن لمشاكل التعدد أن تؤثر على دقة وإستقرار المعالم المقدرة، ولكن الآثار الحقيقية للتعدد الخطي لم تحدد نظريا بعد. إن التعدد الخطي ليس بشرط يجب توفره أو عدم توفره في الدوال الإقتصادية، وإنما هي ظاهرة تشوب معظم العلاقات تبعا للتصرفات الإقتصادية. ولا توجد أدلة قطعية<sup>(10)</sup> حول درجة التعدد الخطي التي تؤثر بوضوح على مقدرات المعالم، حيث

9- أنظر:

A. Goldberger: "Econometric Theory". John Weily. New York. Page 201, 1964

10- أنظر:

- A.Koutsoyiannis : "Theory of Econometrics". Mac-Millan press L.T.D. London. 1983. PP:233-252



يوجد إتجاه في المتغيرات الإقتصادية لأن تتحرك معا عبر الزمن، وتتأثر التصرفات الإقتصادية بنفس العوامل. فمثلا، في فترات الرواج أو النمو الإقتصادي السريع تنمو التصرفات الإقتصادية الأساسية رغم أن بعضها ينمو ضمنا تحت غطاء بعض المتغيرات الأخرى. إن النمو وعوامل الإتجاه العام Trend هي إحدى الأسباب الرئيسية في بيانات السلاسل الزمنية. المسببة للتعدد الخطي. كما أن استعمال القيم المؤخرة Lagged Values لبعض المتغيرات المستقلة منفصلة في العلاقة المدروسة يساعد على ظهور هذا المشكل. فالنماذج المؤخرة أعطت نتائج إيجابية في عدة ميادين من القياس الإقتصادي التطبيقي Applied Econometrics. وأصبح استعمالها بشكل واضح في السنوات الأخيرة. فمثلا، في دوال الإستهلاك أصبح طبيعيا إدخال القيم السابقة للدخل والدخل الحالي (الجاري) مع المتغيرات المستقلة الأخرى في تحديد العلاقة. ومن ثم فإنه من الطبيعي أن تكون القيم المتوالية لمتغير معين مرتبطة فيما بينها، حيث يكون دخل الفترة الحالية. مثلا. محدد جزئيا بواسطة قيمته في الفترة السابقة وهكذا. نستنتج أن هناك درجة معينة من الارتباط متوقعة الظهور في أغلب العلاقات الإقتصادية. ونشير إلى أنه بالرغم من أن التعدد الخطي، يكون، عادة، ملازما لبيانات السلاسل الزمنية، فإنه يمكن أن يظهر مع البيانات المقطعية، ولنفرض أننا نريد تقدير المعادلة التالية:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t \dots (4.106)$$

وإذا كانت  $\lambda = X_{3t} / X_{2t}$ ، يكون أي تحرك للمتغير  $X_2$  متبوعا بتحرك  $X_3$ ، ولا يمكننا فصل أثر  $X_2$  على  $Y$  بدون المتغير  $X_3$ . وبالتعويض نجد:

$$Y_t = \beta_1 + (\beta_2 + \lambda \beta_3) X_{2t} + u_t \dots (4.107)$$

ومنه نستطيع تقدير المقدار  $(\beta_2 + \lambda \beta_3)$ ، ولا يمكننا الفصل بين  $\beta_2$  و  $\beta_3$  من أجل الحصول على مقدرتيهما المنفصلتين. أي إذا كانت رتبة  $X$  أقل من  $k$ ، فإن المصفوفة  $X'X$  تكون بدون معكوس. لأن محددها يساوي الصفر، ومنه



لا يمكن حساب مقدار المربعات الصغرى العادية  $\hat{\beta}$  كما أشرنا لذلك من قبل وتسمى هذه الحالة بالتعدد الخطي التام أي  $\Gamma_{X_i X_j} = 1$  . ويأتي مشكل التعدد الخطي، كما ذكرنا، على عدة مستويات (درجات)، وأبسط حالة يظهر بها هذا الأخير هي لما يكون أي متغيرين مستقلين مرتبطين بدرجة عالية ولكن ليست تامة. فإذا كان عمودان للمصفوفة  $X$  مرتبطين بدرجة عالية، يعني ذلك أن محدد المصفوفة  $X'X$  سوف يكون قريبا من الصفر، ومنه تكون عناصر المصفوفة  $(X'X)^{-1}$  كبيرة جدا. ومن نتائج ذلك هو أن تباينات المقدرات  $\hat{\beta}_j$  تكون كبيرة وبالتالي تكون أخطاءها المعيارية كذلك كبيرة مادام:

$$SE(\hat{\beta}_j) = \hat{\sigma}_u \sqrt{a_{jj}} \quad (11)$$

ومنه تكون  $\hat{\beta}_j$  غير محددة بطريقة فعالة ومناسبة. كما أن الإحصاءة  $t$  تصبح صغيرة. ويمكن إستخلاص أن مؤشرات وجود التعدد الخطي هي قيمة كبيرة لمعامل التحديد  $R^2$  مع مقدرات معالم مرفوضة المعنوية. وهذا يعني أن واحدا أو أكثر من المتغيرات المستقلة لها أثر منتظم في المتغير التابع، ولكننا لانستطيع معرفة أي واحد من هذه المتغيرات بالضبط. فلما ندخل متغيرا مستقلا للمعادلة بدون البقية، وتكون النتيجة إيجابية، بينما عند إدخال بقية المتغيرات تصبح معنوياتها الفردية مرفوضة. نستنتج أن هذا دليل على وجود التعدد الخطي. ويجب الإنتباه إلى أنه لايمكننا، دائما، إكتشاف التعدد الخطي بالإعتماد على معادلات الارتباط الخطي الجزئية البسيطة فقط. ففي المعادلة (106.4) إذا كانت لدينا العلاقة  $X_{3t} = X_{2t} + \beta_1$ ، نكون مع حالة التعدد الخطي التام. ومع هذا فإن معامل الارتباط البسيط مابين  $X_{3t}$  و  $X_{2t}$  يمكن أن يكون منخفضا. كما يجب الملاحظة بأن الارتباط مابين المتغيرات المستقلة هو معدل طبيعي وعادي وليس بمشكل. حيث في حالة غياب هذا الارتباط تكون المصفوفة  $X'X$  قطرية. ومنه تكون كل مقدرات

<sup>11</sup> - إن  $a_{jj}$  هي القطر  $j$  للمصفوفة  $(X'X)^{-1}$  كما عرفناها بالفصل الثالث.

المعالم، للإتحاد المتعدد، عبارة عن مقدرات مجموعة إتحادات بسيطة. إذا كانت درجة إرتباط المتغيرات المستقلة لنموذج ما تنتمي للمجال  $0 < r_{x_i x_j} < 1$ ، فإن أثر التعدد الخطي يكون غير واضح. حيث في بعض الأحيان، تكون قيم المعالم المقدرة غير مستقرة كلما أضفنا متغيرات مرتبطة خطيا للدالة، أو كلما توسع حجم العينة. وفي أحيان أخرى لا تتأثر المعنوية الإحصائية لقيم المعالم المقدرة. كما أن قيم المعالم المقدرة تبقى دائما غير متحيزة إحصائيا حتى لما تكون درجة التعدد الخطي قوية. لأن الخاصية الإحصائية لعدم التحيز، بالنسبة لمقدرات المربعات الصغرى العادية، لا تتطلب بأن تكون قيم المتغيرات المستقلة،  $X$ ، غير مرتبطة خطيا فيما بينها. بينما وجود التعدد الخطي يمكن أن يؤدي، عادة، إلى تغيرات كبيرة في قيم المعالم المقدرة (مثل تغير الإشارة). ويعتمد ذلك على أهمية ذلك المتغير المستقل والمعني بظاهرة التعدد الخطي. ويعلن الكاتب <sup>(12)</sup> Klein بأن الإرتباط الخطي ليس بمشكلة حقيقية، إلا إذا كانت قيمته عالية بالمقارنة مع درجة معامل التحديد المضاعف من خلال كل المتغيرات، أي أن الإرتباط أو التعدد الخطي يسبب مشكلا عويصا إذا كانت:

$$r^2_{x_i x_j} \geq R^2 \quad (13)$$

#### 4-6-1 إختبارات إكتشاف التعدد الخطي:

تعتمد درجة الخطورة لأثر التعدد الخطي على درجة الإرتباط الجزئي، ومعامل الإرتباط الكلي (أو معامل التحديد المضاعف). ومنه يمكن القول بأن

12 - أنظر:

- L.R.Klein : "Introduction to Econometrics"  
Prentice- Hall international, London, 1971. pp 64 and 101

13- إن  $r_{x_i x_j}$  هو معامل الإرتباط البسيط ما بين  $x_i$  و  $x_j$  بينما  $R^2$  هو معامل التحديد

المضاعف ما بين المتغير التابع  $Y_i$  وبقية المتغيرات المستقلة  $x_j$   $J=1,2,...,k$



كلا من الأخطاء المعيارية، معاملات الارتباط الجزئية  $r_{xixj}$ ، معامل التحديد المضاعف  $R^2$ ، يمكنها أن تستعمل لإختبار التعدد الخطي. لكن كل معيار من المعايير الثلاثة المذكورة ليس بمؤشر على وجود التعدد الخطي بمفرده. وذلك لأن القيم العالية للأخطاء المعيارية لا تظهر، دائما، بسبب التعدد الخطي وإنما يمكن أن تظهر لأسباب أخرى. كما أن الارتباطات العالية فيما بين المتغيرات المستقلة لا تؤثر بالضرورة على قيم المقدرات  $\hat{\beta}_j$ . ومنه ليست هذه الأخيرة بمعيار مناسب لقياس وإكتشاف التعدد الخطي بمفردها. وبالمقابل يمكن لقيمة معامل التحديد المضاعف  $R^2$  أن تكون عالية بالمقارنة مع  $r_{xixj}$ . ورغم ذلك، من المحتمل، أن تحتوي نتائجنا على إشارات خاطئة أو على أخطاء معيارية كبيرة. ومع كل هذا، يمكن القول بأن توفيق المعايير الثلاثة، أعلاه، يساعدنا على إكتشاف التعدد الخطي.

#### 4-6-1-1 طريقة التحليل الترادفي لـ Frisch:

وتكمن هذه الطريقة في تحديد المتغير التابع في كل متغير مستقل على حدى، ومنه نحصل على كل الإنحدارات الأولية. ثم نختبر نتائجنا الإحصائية بناءا على المعايير الإقتصادية المعروفة مسبقا. نختار الإنحدار الأولي الذي يعطي النتائج الأكثر مصداقية. ثم نضيف تدريجيا متغيرات أخرى ونختبر آثارها على كل من المعالم الفردية (أخطائها المعيارية، قيمة  $R^2$ ). ويكون المتغير المضاف للإنحدار ذا مغنوية إذا تحققت فيه الشروط التالية:

(a) إذا حسن المتغير المستقل الجديد من  $R^2$  بدون أن يجعل المعالم الفردية مرفوضة بطريقة خاطئة، نحفظ بهذا المتغير ونعتبره كمتغير مستقل.



(b) إذا لم يحسن المتغير الجديد من العلاقة ويؤثر على قيم المعالم الفردية، نعتبره مرفوضا ونحذفه من الإتحاد.

(c) إذا أثر المتغير الجديد بشكل واضح على إشارات وقيم المعالم المقدرة، نعتبره متغيرا مفسرا. فإذا تأثرت المعالم الفردية بالطريقة التي تصبح فيها غير مقبولة على أساس الإعتبارات النظرية المعروفة مسبقا، فإنه يمكننا القول بأنه مؤثر على وجود التعدد الخطي بشكل معقد. يكون هذا المتغير مهما، لكن بسبب الإرتباطات الخطية مع المتغيرات المستقلة الأخرى، يكون أثره غير مقدر وغير معروف إحصائيا بواسطة المربعات الصغرى العادية، ولتخاشي تعقيدات التعدد الخطي والأخذ بعين الإعتبار أثر المتغير المفسر يجب علينا إتباع إحدى الحلول المذكورة بفقرة الحلول المقترحة للتعدد الخطي لاحقا. لأن حذف المتغير المفسر تماما من الإتحاد، لتخاشي أثره المضر على بقية المعالم، سوف يترك هذا الأثر ضمنيا على المعالم الأخرى (المتغيرات المستقلة الأخرى)، وعلى الحد العشوائي ( $u_j$ ) الذي يصبح، أتوماتيكيا، مرتبطا مع بقية المتغيرات المستقلة الأخرى في الدالة، وتصبح الفرضية  $E(X_i u_j) = 0$  غير صحيحة.

إن التحليل الترافدي لـ Frisch ينص على تقدير كل الإتحادات الممكنة ما بين المتغيرات الموجودة بالعلاقة المدروسة، آخذين كل متغير، بالترتيب، كمتغير تابع وإعتبار كل الإتحادات الممكنة لكل متغير في بقية المتغيرات، والتي ندخلها تدريجيا في التحليل. ومن الواضح أن التحليل الترافدي يتطلب منا حسابات كثيرة، ومنه تكون المقارنات مابين النتائج معقدة أكثر.

#### 4-1-6-2 قياس التعدد الخطي أو شرط الأعداد Condition numbers

من نموذج الفصل الثالث بالمعادلة (1.3) لدينا:

$$\text{var}(\hat{\beta}_2) = \frac{\sigma_u^2}{\sum x_{2i}^2 (1 - R_2^2)} \quad (14) \dots (4.108)$$

$$\text{var}(\hat{\beta}_3) = \frac{\sigma_u^2}{\sum x_{3i}^2 (1 - R_3^2)} \dots (4.109)$$

$$\text{cov}(\hat{\beta}_2, \hat{\beta}_3) = \frac{\sigma_u^2 R_2^2}{\sum x_{2i} x_{3i} (1 - R_2^2)} \dots (4.110)$$

حيث أن  $R_2^2$  هو مربع معامل الارتباط المتعدد مابين المتغيرين المستقلين  $X_{2i}$  و  $X_{3i}$ ، بينما  $R_3^2$  هو نفسه معامل الارتباط المتعدد ولكن مابين  $X_{2i}$  و  $X_{3i}$  وهما في الأخير متساويان. أما عند توسيع النموذج (1.3) إلى  $k$  متغير مستقل  $k > 2$  يصبح  $R_j^2 (J > 2)$  على أنه مربع معامل الارتباط المتعدد مابين المتغير المستقل  $X_j$  وبقية المتغيرات المستقلة الأخرى. ومنه يمكننا إستنتاج قانون عام لتباين المقدرات الفردية لموجه معالم الإنحدار الخطي كما يلي:

$$\text{var}(\hat{\beta}_j) = \frac{\sigma_u^2}{\sum x_{ji}^2 (1 - R_j^2)} : j = 1, 2, \dots, k \dots (4.111)$$

وتكون قيمة  $\text{var}(\hat{\beta}_j)$  كبيرة كلما كانت:

(a)  $\sigma_u^2$  كبيرة

(b)  $\sum x_{ji}^2$  صغيرة

(c)  $R_j^2$  كبيرة

14- لاحظ أنه في حالة المعادلة (1.3) بالفصل الثالث فإنه يكون  $R_2^2 = R_3^2$ .



ومنه نعرف مقياسا جديدا يسمى "معامل تضخم التباين" **Variance-Inflation factor (V.I.F)**، ومقياسا آخر يسمى "شرط العدد" **Condition number**، وهما مقياسان يحددان درجة التعدد الخطي. ويعرف معامل تضخم التباين كمايلي:

$$V.I.F(\hat{\beta}_j) = \frac{1}{1 - R_j^2} \dots (4.112)$$

وبناءا على تعريف V.I.F أعلاه، تصبح المعادلة (112.4) على الشكل:

$$\text{var}(\hat{\beta}_j) = \frac{\sigma_u^2}{\sum x_{ji}^2} \cdot V.I.F(\hat{\beta}_j) \dots (4.113)$$

أي أن:

$$V.I.F(\hat{\beta}_j) = \frac{\sum x_{ji}^2}{\sigma_u^2} \cdot \text{var}(\hat{\beta}_j)$$

وإنطلاقا من الإنتقادات الموجهة لمعامل الارتباط، يكون مقياس VIF غير كاف لتحديد التعدد الخطي. ومنه نضيف مقياس شرط الأعداد المذكور من طرف Welsch 1980، والذي يقيس حساسية مقدرات الإنحدار للتغيرات الصغيرة في التباينات. ويعرف شرط الأعداد على أنه الجذر التربيعي لأكبر قيمة مقسمة على أصغر قيمة للقيم المميزة eigen values للمصفوفة  $X'X$  وهو على الشكل:

$$k(X) = \frac{\sqrt{\lambda_{\max}}}{\sqrt{\lambda_{\min}}} (15)$$

فكلما كانت القيمة اعلاه أقرب إلى الواحد، كلما كان الشرط أفضل لعدم جدية التعدد الخطي، ومع هذا، فإن المقياسين المذكورين أعلاه ليسا كاملين. حيث أن القانون الموجود بالمعادلة (112.4) ينظر إلى الارتباطات من خلال المتغيرات المستقلة فقط وهذا ليس بالعامل الوحيد. كما أن شرط العدد يمكن أن يتغير بإعادة تحويل

15- أنظر:

- J. Johnston "Econometric Methods" Mac Graw-Hill. London 1984. PP 249-250



المتغيرات المستقلة والتي ليست دائما صحيحة. ويصلح المقياسان (VIF و شرط العدد) للاستعمال عند حذف بعض المتغيرات وفرض قيود على المعالم فقط في الحالات التي يكون فيها  $R_j^2 \approx 1$ ، أو لما تكون القيمة المميزة الصغيرة  $\lambda_{\min}$  أقرب من الصفر. نقدر النموذج في هذه الحالة تبعا لبعض القيود المفروضة على معالمه. ويقترح (16) Theil مقياسا آخر لقياس درجة الارتباط فيما بين المتغيرات ومنه درجة التعدد الخطي على الشكل:

$$m = R^2 - \sum_{j=2}^k (R^2 - R_{-j}^2) \dots (4.114)$$

حيث أن  $R^2$  هو معامل التحديد المضاعف المعروف من قبل، أما  $R_{-j}^2$  فهو مربع معامل الارتباط المتعدد من إحدار  $y$  (المركزة) في  $X_2, X_3, \dots, X_k$  مع حذف  $X_j$ . لكن إحدى عيوب هذه الطريقة، هي أن  $m$  يمكن أن تكون سالبة مما يجعل التحليل أصعب. وهناك من يقترح طرقا معينة لحل مشكلة التعدد الخطي كإضافة حد ثابت لتباينات مقدرات المعالم قبل حل المعادلات الطبيعية للمربعات الصغرى (17).

#### 3-1-6-4 طريقة (18) Farrar-Glauber

لاكتشاف ظاهرة التعدد الخطي يتبع Farrar-Glauber الخطة التالية:  
(a) حساب مربع معامل الارتباط المتعدد بالنسبة لكل المتغيرات المستقلة بالترتيب  $R_j^2$ .

16- أنظر:

- H. Theil "Principales of Econometrics". New York, Wiley 1971, page 179

17- أنظر:

- G.S. Maddala "Introduction to Econometrics": Mac Millan Publishing Company New York. 1988. Page 234.

18- أنظر:

- D.E. Farrar and R.R. Glauber "Multicollinearity in regression Analysis" Revue of Econometrics and Statistics, Vol 49, 1967, PP:92-207.

(b) إختبار المغنوية الإحصائية لمعاملات الارتباط المتعددة بواسطة التوزيع F كمايلي:

$$F = \frac{R_j^2 / (k - 1)}{(1 - R_j^2) / (n - k)} \sim F_{k-1, n-k} \dots (4.115)$$

وتكون الفرضية المختبرة هي:  $H_0: R_j^2 = 0$  us:  $H_A: R_j^2 \neq 0$  فإذا كانت قيمة F المحسوبة أكبر من تلك المجدولة نقبل  $H_A$  ويكون المتغير  $X_j$  متعدد أو مرتبط خطيا. أما إذا حدث العكس نقبل  $H_0$  ولا يكون هناك أثر لتعدد  $X_j$  خطيا.

#### 2-6-4 الحلول المقترحة للتعدد الخطي

عند وجود التعدد الخطي، فإن الحلول تكون معتمدة على إمكانية إيجاد مصادر أخرى للبيانات، وعلى أهمية العوامل التي تسببت في ظهورها، ثم على الهدف الذي من أجله نقوم بتقدير الدالة تحت الدراسة. فإذا لم يؤثر التعدد الخطي بشكل فعلي على مقدرات النموذج، يقترح بعض باحثي القياس الإقتصادي إهمال وجوده بالنموذج. حيث يمكن تحاشي التعدد الخطي بتوسيع حجم العينة، فمثلا، يمكن تحويل البيانات السنوية إلى بيانات موسمية أو شهرية إن أمكن ذلك. كما يمكن التخلص من التعدد الخطي بإسقاط (حذف) المتغير المسبب لهذا المشكل لكن هذه العملية يمكن أن تسبب مشاكل أخرى كما لاحظنا في فقرة "إضافة محدرات والحذف غير الصحيح لمحدرات". وهناك من يقترح (19) إدخال معلومات إضافية للنموذج.

19 - أنظر:

- M.B. Stewart and K.F. Wallis "Introductory Econometrics" Basil Black Well, Oxford 1981, Page 153.



- إن وجود التعدد الخطي يجعل من الصعب فصل آثار المتغيرات المختلفة. ومنه نحتاج إلى معلومات خاصة تساعدنا على فصل أثر كل متغير لوحده. ويكون ذلك عن طريق فرض قيود على بعض المعالم بناءً على المعلومات المسبقة للنظرية الإقتصادية (أنظر فقرة القيود الخطية مثلاً). ففي دالة كوب-دوغلاس للإنتاج، إذا عرفنا مرحلة الإنتاج التي تمر بها المؤسسة المعنية بالدراسة، يمكن للنظرية الإقتصادية أن تجبرنا على فرض قيود على المعاملات التقنية للإنتاج وفقاً لثبات قانون الغلة، تزايدها أو تناقصها.

#### 3-6-4 مثال (1.4): طريقة Frisch لاكتشاف التعدد الخطي:

لدينا الجدول (1.4) أدناه مع بيانات السلاسل الزمنية للفترة 1959-1968. للإتفاق على الملابس (C)، الدخل المتاح (Y)، السيولة النقدية (L)، مؤشر أسعار الملابس ( $P_C$ )، و المؤشر العام للأسعار ( $P_0$ ) في دولة ما (20).



السنوات	C (ع1)	Y (21)	L (2\)	P <sub>c</sub> 1963=100	P <sub>0</sub> 1963=100
1959	8.4	82.9	17.1	92	94
60	9.6	88	21.3	93	96
61	10.4	99.9	25.1	96	97
62	11.4	105.3	29	94	97
63	12.2	117.7	34	100	100
64	14.2	131	40	101	101
65	15.8	148.2	44	105	104
66	17.8	161.8	49	112	109
67	19.3	164.2	51	112	111
68	20.8	184.7	53	112	111

-جدول (1.4)-

وبناء على مقاييس النظرية الإقتصادية المعروفة مسبقا. يكون الإنفاق الإستهلاكي على الملابس متأثرا بكل العوامل المذكورة أعلاه. ومنه تكون دالة الطلب على الملابس كمايلي:

$$C_t = \beta_1 + \beta_2 Y_t + \beta_3 L_t + \beta_4 P_{ct} + \beta_5 P_{0t} + u_t$$

وبتطبيق قانون المربعات الصغرى العادية نجد:

2\ - الأرقام معطاة بملايين الجنيهات الإستراتيجية

21 - الأرقام معطاة بملايين الجنيهات الإستراتيجية

2\ - الأرقام معطاة بملايين الجنيهات الإستراتيجية

$$\hat{C}_t = -13,53 + 0,097Y_t + 0,015L_t - 0,199P_{ct} + 0,34P_{ot}$$

$$S.E \quad (7,5) \quad (0,03) \quad (0,05) \quad (0,09) \quad (0,15)$$

$$R^2 = 0,998, \quad ESS = 28,15, \quad RSS = 0,33, \quad D - W = 3,4$$

وإذا أردنا اختبار معنوية أميال الإنحدار، بتطبيق قانون التوزيع F، لتحليل التباين والمذكور بالمعادلة (71.3) بالفصل الثالث نجد:

$$F = \frac{ESS/(k-1)}{RSS/(n-k)} = \frac{28,15/4}{0,33/5} = 15,6 \sim F_{4,5}$$

ثم بالرجوع إل قيمة F، المجدولة بمستوى معنوية  $\lambda = 0,05$  يكون  $F^* = 5,19$ . أي القيمة المحسوبة أكبر من المجدولة ومنه نرفض  $H_0$  ونقبل  $H_A$  التي تؤكد بأن المعنوية الكلية لأميال الإنحدار مقبولة إحصائيا. بينما نلاحظ أن كل المتغيرات المستقلة لها تعدد خطي مثلما تبين ذلك معاملات الارتباط الجزئية البسيطة كمايلي:

$$r_{Y,L} = 0,993$$

$$r_{LPC} = 0,964$$

$$r_{Y,P_c} = 0,98$$

$$r_{LPO} = 0,973$$

$$r_{Y,P_o} = 0,987$$

$$r_{PC \cdot PO} = 0,991$$

ولتوضيح آثار التعدد الخطي نحسب الإنحدارات الأولية المذكورة بالفقرة السابقة على النحو:

$$1 - \hat{C}_t = \hat{\alpha} + \hat{\beta}Y_t = -1,24 + 0,118Y_t: \quad R^2 = 0,995, D - W = 2,6$$

$$S.E \quad (0,37) \quad (0,02)$$

$$2 - \hat{C}_t = \hat{a} + \hat{b}P_{ct} = -38,51 + 0,516P_{ct}: \quad R^2 = 0,951, D - W = 2,4$$

$$S.E \quad (4,2) \quad (0,04)$$

$$3 - \hat{C}_1 = \hat{A} + \hat{B}L_1 = 2.11 + 0.327L_1 \quad R^2 = 0.967, D-W = 0.4$$

$$S.E \quad (0.81) \quad (0.02)$$

$$4 - \hat{C}_2 = \hat{\delta} + \hat{\gamma}P_1 = -53.65 + 0.663P_1 \quad R^2 = 0.977, D-W = 2.1$$

$$S.E \quad (3.63) \quad (0.03)$$

ومادام الدخل المتاح  $Y$  يعتبر المتغير المستقل الأهم في دالة الطلب على الملابس خلال فترة الدراسة. فإننا نختار الإنحدار الأول  $C = f(Y)$  كخطوة أولى في تحليلنا. ثم ندخل بقية المتغيرات المستقلة الأخرى بالتدريج لدالة الطلب. ونورد نتائج ذلك في الجدول (2.4) التالي:

المقدرات	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$	$\hat{\beta}_5$	$R^2$	DW
الدالة							
$C = f(Y)$	-1,24 (0,37)	0,118 (0,002)	--	--	--	0,995	2,6
$C = f(Y, P_1)$	1,40 (4,92)	0,126 (0,01)	-0,036 (0,07)	--	--	0,996	2,5
$C = f(Y, P_1, L_1)$	0,94 (5,17)	0,138 (0,02)	-0,034 (0,06)	0,037 (0,05)	--	0,996	3,1
$C = f(Y, P_1, P_2)$	-12,76 (6,52)	0,104 (0,01)	-0,188 (0,07)	--	0,319 (0,12)	0,997	3,5
$C = f(Y, P_1, L_1, E)$	-13,53 (7,5)	0,097 (0,03)	-0,199 (0,09)	0,015 (0,05)	0,34 (0,15)	0,998	3,4

-جدول (2.4)-

وتظهر تغيرات الدخل بأنها مهمة في شرح التغيرات الكلية في الإنفاق على الملابس. كما أن إدخال مؤشر أسعار الملابس  $P_C$  يحسن بوضوح من قيمة  $R^2$ .



إن إشارات موجه المقدرات  $\hat{\beta}$  صحيحة ولكن الأخطاء المعيارية تبين بأن  $\hat{\beta}_3$  غير ضروري إحصائيا، كما أن الارتباط الكبير مابين  $Y$  و  $P_c$ ، ( $r_{Y,P_c} = 0,98$ )، لا يؤثر على استقرار ومعنوية المقدّر  $\hat{\beta}_2$ . إن إدخال متغير السيولة النقدية ( $L$ ) لا يعطي مقدرا جيدا ومضبوطا لكل من المقدرتين  $\hat{\beta}_3$  و  $\hat{\beta}_4$ . وواضح أن الارتباط الكبير مابين  $P_c$  و  $L$ ، ( $r_{P_c,L} = 0,964$ )، يجعل من المستحيل الحصول على معنى منفصل للمقدرتين  $\hat{\beta}_3$  و  $\hat{\beta}_4$ . وبالرغم من الارتباط القوي مابين  $Y$ ،  $P_c$  و  $L$ . فإن المقدّر  $\hat{\beta}_2$  لم يتأثر. ومنه يمكن اعتبار  $L$  كمتغير غير ضروري (زائد). إن حذف متغير السيولة النقدية،  $L$ ، وإدخال متغير المؤشر العام للأسعار  $P_0$  يعطي توفيقا جيدا. حيث ترتفع قيمة  $R^2$  بشكل واضح، وتأخذ كل مقدرات المعالم الإشارة الصحيحة. وتكون معنوياتها مقبولة إحصائيا. كما أنه، بالرغم من درجة التعدد الخطي العالية لكل المحدرات، فإن قيم الأخطاء المعيارية ليست كبيرة. إن الإنحدار الأخير (الكامل). يبين بأن، أثر التعدد الخطي لا يسبب مشاكل تذكر بالنسبة للمقدرتين  $\hat{\beta}_2$ ،  $\hat{\beta}_3$ . بينما مقدّر معلمة السيولة النقدية،  $\hat{\beta}_4$ ، يكون غير مقبول إحصائيا. ومنه يكون متغير السيولة النقدية، عبارة عن متغير غير ضروري (زائد) ونستنتج بأن أحسن توفيق لدالة الطلب على الملابس هو:

$$C = f(Y, P_c, P_0)$$

#### 4-6-4 مثال (2.4) عن التغير الهيكلي:

لنأخذ المثال (1.2) والمذكور بالفصل الثاني لدالة الإستهلاك للأفراد الجزائريين بالأسعار الحقيقية خلال الفترة 1967-1989. وإذا أردنا اختبار وجود تغير هيكلي في معالم الإنحدار خلال الفترتين المختلفتين. الأولى (67-78)،  $n_1 = 12$ ، والثانية خلال (79-89)،  $n_2 = 11$ ، فنكتب:

$$I: Y_t = \beta_1 + \beta_2 X_t + u_t: \quad t = 1967, 1968, \dots, 1978$$

$$II: Y_t = \gamma_1 + \gamma_2 X_t + u_t: \quad t = 1979, 1980, \dots, 1989$$

وتكون فرضية عدم وجود تغير هيكلي في معالم النموذج خلال الفترتين الزمنيةتين المذكورتين أعلاه على الشكل:

$$H_0: \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} = \begin{pmatrix} \gamma_1 \\ \gamma_2 \end{pmatrix}$$

نجري إحدار النموذج I للفترة الأولى بواسطة المربعات الصغرى العادية لنجد:

$$I: \hat{Y}_t = -1020 + 1,165X_t: \quad t = 1967, 1968, \dots, 1978$$

$$S.E \quad (191,8) \quad (0,055)$$

$$R^2 = 0,978, \quad \bar{R}^2 = 0,976, \quad RSS_1 = 99522,37, \quad D-W = 1,77$$

$$\hat{\sigma}_u = 99,76, \quad F_{1,10} = 450,5, \quad n_1 = 12$$

وكذلك بالنسبة للنموذج II نجد:

$$II: \hat{Y}_t = 15,26 + 0,884X_t: \quad t = 1979, \dots, 1989$$

$$S.E \quad (803,5) \quad (0,157)$$

$$R^2 = 0,779, \quad \bar{R}^2 = 0,754, \quad RSS_2 = 169534,3, \quad D-W = 2,04$$

$$\hat{\sigma}_u = 137,25, \quad F_{1,9} = 31,73, \quad n_2 = 11$$

ثم نجري إحدار النموذج تحت الفرضية  $H_0$  صحيحة للفترتين الزمنيةتين معا لنجد:

$$H_0: \hat{Y}_t = -343,15 + 0,96X_t: t = 1967, \dots, 1989$$

$$S.E \quad (140,5) \quad (0,032)$$

$$R^2 = 0,976, \quad \bar{R}^2 = 0,975, \quad RSS = 436351,1, \quad D - W = 1,30$$

$$\hat{\sigma}_u = 144,15, \quad F_{1,21} = 883,49, \quad n = n_1 + n_2 = 23$$

ومنه تكون مجموع مربعات البواقي غير المقيدة هي:

$$URSS = RSS_1 + RSS_2$$

بدرجات حرية هي:

$$(n_1 - k) + (n_2 - k) = n_1 + n_2 - 2k = n - 2k$$

أما بالنسبة للنموذج المقيد تحت  $H_0$  صحيحة تكون مجموع مربعات البواقي المقيدة هي.  $RRSS$  وبدرجات حرية هي  $n - k = n_1 + n_2 - k$  ومنه نكون إختبار التوزيع  $F$  لتحليل التباين والوجود بالمعادلة (75.4) كمايلي:

$$F = \frac{(RRSS - URSS)/k}{URSS/(n - k)} \sim F_{k, n-k}$$

$$= \frac{[436351,1 - (99522,37 + 169534,3)]/2}{(99522,37 + 169534,3)/19} = 6,5 \sim F_{2,19}$$

أما القيمة المجدولة عند  $\lambda = 0,05$  فهي  $F^* = 3,522$  ومنه نلاحظ أن القيمة المحسوبة أكبر من تلك المجدولة وبالتالي نستنتج بأن  $H_0$  مرفوضة. ومنه يوجد تغير هيكلّي مابين الفترتين المذكورتين أعلاه. ويكون النموذج غير مستقر خلال العينتين  $\Pi_1$  و  $\Pi_2$ .



## 7-4 سلسلة تمارين حول الفصل الرابع

التمرين الأول: يعطى لك نموذج الإنحدار الخطي على الشكل:

$$Y_i = \beta_1 + \beta_2 X_{2i} + u_i$$

مع فرضياته الأساسية.

(a) اشتق عبارة جبرية لقانون التوزيع  $F$  المناسب للعلاقة أعلاه. وما هي الفرضية المختبرة. وبين العلاقة الموجودة بين التوزيع  $F$  والتوزيع  $t$ .

(b) إذا أضفنا متغيرا مستقلا جديدا للنموذج أعلاه. وليكن  $X_{3i}$ . أوجد المعادلات الطبيعية للمربعات الصغرى. وأحسب معامل التحديد المضاعف ثم قارنه بمثيله بالفرع (a).

(c) إذا أضفنا متغيرا مستقلا آخر للعلاقة في (b) وليكن  $X_{4i}$ . اشتق عبارة جبرية لقانون التوزيع الذي يختبر الفرضية  $H_0: \beta_2 = \beta_1 = 0$ .

(d) إذا كانت  $\beta_1 = 0$  صحيحة. فاثبت أن مجموع مربعات البواقي للنموذج الجديد هي أكبر من مثيلتها في نموذج العلاقة ب (c).

(e) إذا كان نموذج العلاقة (c) هو الصحيح. وقمنا بتقدير النموذج الموجود بالعلاقة (b) ماذا يحدث لخصائص مقدرات المربعات الصغرى؟

(f) إذا كان نموذج العلاقة (a) هو الصحيح. وقمنا بتقدير نموذج العلاقة (c) ما أثر ذلك على خصائص مقدرات المربعات الصغرى؟

(g) إذا أردنا التأكد من صحة العلاقة (a) أو (c) اختبر الفرضية:

$$H_0: \begin{pmatrix} \beta_2 \\ \beta_1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} = \gamma$$

التمرين الثاني: لنكتب نموذج الإحداد الخطي العام  $Y = X\beta + U$  على الشكل:

$$Y = X_1\beta_1 + X_2\beta_2 + U$$

حيث أن  $\beta_2$  هو  $X = [X_1 \quad \vdots \quad X_2]$ ،  $\beta' = [\beta'_1 \quad \vdots \quad \beta'_2]$  هو  $(p \times 1)$ ،  $\beta_1$  هو  $(k - p) \times 1$ . ونريد إختبار الفرضية:  
 $H_0: \beta_2 = 0$

ولتحقيق ذلك نقوم بالتعريف التالي:

$$\hat{\beta} = AY, \quad M = I - X(X'X)^{-1}X', \quad A = (X'X)^{-1}X'$$

$$\hat{\beta}_i = A_i Y, \quad M_i = I - X_i(X_i'X_i)^{-1}X_i', \quad A_i = (X_i'X_i)^{-1}X_i'$$

$$: i = 1, 2.$$

بين صحة العبارات التالية:

$$H_0: \beta_2 = 0 \Rightarrow (U'M_1U)/\sigma_u^2 \sim \chi_{n-(k-p)}^2 \quad (a)$$

$$H_A: \beta_2 \neq 0 \Rightarrow (U'MU)/\sigma_u^2 \sim \chi_{n-k}^2 \quad (b)$$

$$(U'MU - U'M_1U)/\sigma_u^2 \sim \chi_p^2 \quad (c)$$

$$(\chi_p^2/p)(\chi_{n-k}^2/(n-k))^{-1} \sim F_{p,n-k} \quad (d)$$

$$M_1M = M, \quad (M_1 - M)(M_1 - M) = M_1 - M \quad (e)$$

$$X_1 = (X_1 \quad \vdots \quad X_2) \begin{pmatrix} I \\ \dots \\ 0 \end{pmatrix} = XS \quad \text{لاحظ أنه يمكن وضع:}$$

$$X_1'X_2 = 0 \Rightarrow \hat{\beta}_i = (X_i'X_i)^{-1}X_i'Y, \quad E(\hat{\beta}_i - \beta_i) = 0 \quad (f)$$

$$X_1'X_2 \neq 0 \Rightarrow E(\hat{\beta}_1 - \beta_1) \neq 0 \quad (g)$$

$$\hat{U}_1 = Y - X_1\hat{\beta}_1, \quad \hat{U}_2 = X_2 - X_1P \quad (h)$$

$$P = (X_1'X_1)^{-1}X_1'X_2, \quad X_2 = X_1P + U_2,$$

$$U_1, U_2 \sim N(0, \sigma_u^2 I_N)$$

هذا كله يعني ويستلزم أن:

$$b_2 = (\hat{U}_2'\hat{U}_2)^{-1}\hat{U}_2'\hat{U}_1 = \hat{\beta}_2$$

$$E(b_2) = \beta_2 \Rightarrow \text{BLUE}$$

التمرين الثالث: ليكن النموذج الخطي العام التالي:

$$I: Y = X_1\beta_1 + X_2\beta_2 + U$$

حيث أن  $X_1$  هي  $n \times k$ ،  $X_2$  هي  $n \times k_1$ ،  $\beta_1$  هي  $k \times 1$ ،  $\beta_2$  هي  $k_1 \times 1$ .

(a) قدر معالم النموذج بطريقة المربعات الصغرى.

(b) لنفرض أن النموذج الصحيح هو  $\Pi: Y = X_1\beta_1 + U$  قارن مقدار  $\beta_1$  من النموذج  $\Pi$  مع مقدار  $\beta_1$  من النموذج  $I$ .

(c) إذا كان النموذج  $I$  هو الصحيح، وقمنا بتقدير  $\beta_1$  من النموذج  $\Pi$ . ماهي نتائج هذه العملية من حيث التحيز والتباين؟



التمرين الرابع: لنعتبر النموذج الخطي العام التالي:

$$Y = XA + U \quad : t = 1, 2, \dots, 20$$

$$X = [i \quad X_{2t} \quad X_{3t} \quad X_{4t} \quad X_{5t}], \quad A' = [a_1, a_2, a_3, a_4, a_5]$$

ونريد إختبار القيود الخطية التالية:

$$a_1 = 5, \quad 2a_1 + 3a_2 = 4, \quad a_1 + 2a_2 + a_4 = 7$$

( a ) حدد الطريقة التي يمكن بواسطتها إختبار  $H_0$ . ثم أوجد قيم المعالم المقيدة وعدد القيود.

( b ) أوجد درجات الحرية للشكل المقيد والشكل الغير المقيد ونسبة التوزيع  $F$ . وأكتب الشكل المقيد للنموذج أعلاه.

التمرين الخامس: ليكن النموذج الخطي العام:  $Y = X\beta + U$ , مع  $E(UU') = \sigma_u^2 I_n$ . بالإضافة لذلك، هناك معلومات إضافية حول موجه المعالم  $\beta$  متمثلة في القيود الخطية على الشكل  $R\beta = r$ . حيث أن  $R$  هي  $m \times k$  مصفوفة قيود.

( a ) اشتق قانون التوزيع المناسب لهذه القيود وبين شكل الفرضية المختبرة.

( b ) إذا كان حجم العينة  $n = 10$  مع المعلومات التالية:

$$(X'X) = \begin{pmatrix} 10 & 1 \\ 1 & 20 \end{pmatrix}, \quad X'Y = \begin{pmatrix} 2 \\ 5 \end{pmatrix}$$

$$\begin{pmatrix} 2\beta_1 + \beta_2 = 1 \\ \beta_2 = 1 \end{pmatrix}, \quad E(u_i^2) = 1$$

- أحسب موجه المقدرات المقيدة  $\hat{\beta}_R$ ، وكذلك مصفوفة تباينه المشترك
- أحسب موجه مقدرات المربعات الصغرى العادية ومصفوفة تباينه المشترك.
- بين صحة العبارة:  $\text{var}(\hat{\beta}_R) - \text{var}(\hat{\beta}) \leq 0$

التمرين السادس: يمثل النموذج الآتي دالة الطلب على النقود في بلدا.

$$M_{Dt} = \beta_1 + \beta_2 i_t + \beta_3 Y_t + \beta_4 L_t + u_t$$

حيث أن  $M_D$ ،  $i$ ،  $Y$ ،  $L_t$  هي كمية النقود المطلوبة، سعر الفائدة، الدخل الوطني ومخزون الموجودات السائلة على الترتيب. وباستعمال بيانات السلاسل الزمنية للفترة 1920-1957 حصلنا على:

$$\hat{M}_{Dt} = 0,003 - 0,29i_t + 0,53Y_t + 0,367L_t$$

$$SE \quad (0,009) \quad (0,112) \quad (0,101) \quad (0,102)$$

$$TSS = 0,1903, \quad R^2 = 0,579$$

( a ) قيم هذه النتائج من الناحية الإحصائية والاقتصادية

( b ) بدعوى اختبار مدى استقرار دالة الطلب على النقود بالنسبة للفترة الطويلة

(38 سنة)، قمنا بتقسيم الملاحظات إلى عینتين جزئيتين للإتحاديين التاليين:

$$I: \hat{M}_{Dt} = 0,008 - 0,18i_t + 0,517Y_t + 0,281L_t : t = 1920, \dots, 1939$$

$$SE \quad (0,013) \quad (0,15) \quad (0,182) \quad (0,150)$$

$$TSS_1 = 0,0927, \quad R_1^2 = 0,697$$

$$II: \hat{M}_{Dt} = -0,013 - 0,419i_t + 0,936Y_t + 0,587L_t : t = 1940, \dots, 1957$$

$$TSS_2 = 0,0805, \quad R_2^2 = 0,459$$

إن الاختلاف الموجود بين معالم الإتحاديين يقترح علينا وجود تغير هيكل. كون اختبار التغير الهيكلي لـ Chow لكي تقيم فرضية عدم التغير الهيكلي للنموذج.

( c ) إجري اختبار التنبؤ للفترة (1940-1957) وقارنه مع اختبار Chow.

( d ) بين بأن تتبؤ المربعات الصغرى  $\hat{Y}_n^m = X_n^m \hat{\beta}$  هو أحسن تتبؤ من أي تتبؤ خطي غير متحيز آخر على الشكل  $\tilde{Y}_n^m = AY$  والذي يوافق  $E(\tilde{Y}_n^m - Y_n^m) = 0$  مع المتراجحة:  

$$\text{var}(\tilde{Y}_n^m - Y_n^m) - \text{var}(\hat{Y}_n^m - Y_n^m) \geq 0$$

التمرين السابع: لكي نختبر فرضية عدم وجود فرق بين الميل الحدي للإستهلاك عند كل من العمال اليدويين وعمال الإدارة، حصل باحث على الدوال التقديرية:  
i) عمال يدويون:

$$\hat{C}_1 = 120 + 0,90Y: R_1^2 = 0,92, TSS_1 = 3251$$

$$t.s \quad (32) \quad (5,6) \quad n_1 = 35$$

ii) عمال الإدارة:

$$\hat{C}_2 = 160 + 0,82Y: R_2^2 = 0,95, TSS_2 = 4532$$

$$t.s \quad (23) \quad (8,5) \quad n_2 = 30$$

دالة الإستهلاك للعينتين  $n = n_1 + n_2 = 65$  هي:

$$\hat{C} = 250 + 0,70Y: R^2 = 0,92$$

$$t.s \quad (5,3) \quad (6,2) \quad RSS = 16320$$

بإستعمال النتائج السابقة أعلاه، هل بإمكاننا قبول الفرضية القائلة بعدم وجود فرق بالنسبة للميل الحدي للإستهلاك لدى فصيلتي العمال،  $\lambda = 0,05$ ؟



**التمرين الثامن:** لديك بيانات عن دالة الإستهلاك للأفراد الجزائريين بالأسعار الحقيقية للفترة (1987-77) بملايين الدينارات كمايلي:

السنوات	الإستهلاك الفردى $C_t$	الدخل من الأجور $PW_t$	الدخل من الممتلكات $PP_t$
1977	3867,70	2605,21	1393,627
1978	4157,40	3020,25	1444,770
1979	4129,26	3385,73	1579,230
1980	4411,87	3732,69	1633,330
1981	4655,55	3632,15	1639,930
1982	4717,37	3814,17	1636,700
1983	4675,40	3997,01	1570,250
1984	4953,15	3906,41	1540,800
1985	4843,63	3781,73	1558,400
1986	4674,30	3805,68	1551,420
1987	4255,50	3608,54	1647,100

المصدر: الديوان الوطني للإحصائيات ONS.

**a** ) إجري إنحدار العلاقة

$$C_t = \beta_1 + \beta_2 PW_t + \beta_3 PP_t + \beta_4 C_{t-1} + u_t$$

**b** ) طبق طريقة التحليل الترافدي لـ Fisher لإكتشاف التعدد الخطي، ماهي المتغيرات غير الضرورية في الإنحدار أعلاه.

**c** ) إجري الإنحدار بالعلاقة (a) خلال الفترتين:

- الفترة الأولى 1977-1984

- الفترة الثانية 1985-1987

ثم إختبر إستقرار النموذج وماهو نوع الإختبار المستعمل؟

## الفصل الخامس: نظرية العينات الكبيرة

تهتم النظرية التقاربية بتصرف المتغيرات العشوائية عندما يرتفع حجم العينة إلى ما لا نهاية. وللتوضيح أكثر، نقول لتكن  $\bar{a}_n$  تمثل وسط العينة العشوائية لـ  $n$  ملاحظات مسحوبة من مجتمع ما ذو القيم  $a_n$ . إن القيمة  $\bar{a}_n$  هي متغير عشوائي معرف بدالة كثافة احتمالية ممثلة بالشكل  $f(\bar{a}_n/\mu, \sigma^2)$ . حيث نفترض أن دالة كثافتها الاحتمالية، ذات مثلاً  $Z$ ، تحتوي فقط على معلمتين، الوسط  $\mu$  والتباين  $\sigma^2$ . ويكون السؤال الجوهرى في النظرية التقاربية هو كيفية تصرف هذه المتغيرات العشوائية ودوال كثافتها لما يؤول حجم العينة  $n$  إلى ما لا نهاية. ويكون هدفنا هو دراسة التقارب الاحتمالي (التقارب بالاحتمال) والتقارب بالتوزيع. ونظراً لإعتماد الأخيرين على النهاية الاحتمالية ونهاية التوزيع، فإننا نقوم أولاً بالتطرق لمختلف نظريات النهاية الموضحة لذلك.

### 1-5 نظريات النهاية:

تشير كلمة "نظريات النهاية" إلى عدة نظريات في نظرية الاحتمال تحت مختلف الأسماء، وهي قانون الأعداد الكبيرة (Law of Large Numbers (L.L.N) ونظرية النهاية المركزية (Central Limit Theorem (C.L.T). وتشكل نظريات النهاية أحد الركائز المهمة في نظرية الاحتمالات. حيث تلعب دوراً أساسياً في الاستنباط الإحصائي، ويعود أصل هذه النظريات إلى النتيجة المحصل عليها في القرن السابع عشر من طرف الإحصائي James BERNOULLI.



### 1-1-5 نظرية BERNOLLI:

لتكن  $a_n$  تمثل عدد المرات التي تظهر فيه الحادثة  $A$  في  $n$  محاولة لتجربة عشوائية ما، و  $P = P_r(A)$  هي احتمال ظهور الحادثة  $A$  في كل مرة من المحاولات  $n$ . ومنه من أجل أي  $\varepsilon > 0$  فإن:

$$\lim_{n \rightarrow \infty} P_r \left[ \left| \frac{a_n}{n} - P \right| < \varepsilon \right] = 1 \dots (5.1)$$

أي أن نهاية احتمال الحادثة  $\left| \frac{a_n}{n} - P \right| < \varepsilon$  تقترب من الواحد كلما ارتفع عدد المحاولات إلى ما لانهاية.

ومباشرة بعد نشر نتيجة BERNOLLI، فإن DE MOIVRE و LAPLACE اقترحا طريقة أسهل لحساب الإحتمالات الثنائية، وأثبتا أنه لما يكون المقدار  $\left| \frac{a_n}{n} - P \right|$  مضروبا بمقلوب (معكوس) خطئه المعياري فإن النتيجة يكون لها توزيع يقترب من التوزيع الطبيعي لما  $n \rightarrow \infty$ ، أي:

$$\lim_{n \rightarrow \infty} P_r \left[ \left| \frac{\frac{a_n}{n} - P}{\left[ \frac{P(1-P)}{n} \right]^{1/2}} \right| \leq Z \right] = \int_{-\infty}^Z \frac{1}{\sqrt{2\pi}} \exp \left[ -\frac{1}{2} U^2 \right] du \dots (5.2)$$

إن النتيجتين المبينتين أعلاه، تساعدنا على ظهور أدبيات الحجم المرتبطة بمختلف توسيعات نظريتي BERNOLLI و LAPLACE-DEMOIVRE والمطروحة اليوم باسم قانون الأعداد الكبيرة (LLN) ونظرية النهاية المركزية



(CLT) على الترتيب. ولتوسيع النتيجة المذكورتين، نذكر بالشروط الأساسية والمعتمد عليها في الحصول عليهما<sup>(1)</sup>:

$$(a) \quad a_n = \sum_{i=1}^n X_i \quad \text{أي أن } a_n \text{ معرفة على أنها مجموع } n \text{ متغير عشوائي}$$

(b)  $X_i = 1$  إذا ظهر  $A$ ،  $X_i = 0$  غير ذلك،  $i = 1, 2, \dots, n$ . إن  $X_i$  هي متغيرات برنولي العشوائية. ومنه فإن  $a_n$  هي متغير عشوائي يتبع قانون التوزيع الثنائي.

(c)  $X_1, X_2, \dots, X_n$  متغيرات عشوائية مستقلة.

(d)  $f(X_1) = f(X_2) = \dots = f(X_n)$  أي أن  $X_1, X_2, \dots, X_n$  موزعة تماثلًا **Identically distributed** (id) مع

$$i = 1, 2, \dots, n \quad P_r(X_i = 0) = 1 - P, P_r(X_i = 1) = P$$

(e)  $E\left(\frac{a_n}{n}\right) = P$  أي أننا نأخذ بعين الاعتبار الفرق الموجود بين المتغير العشوائي وقيمه المتوقعة.

إن الفرق الأساسي بين نظرية Bernoulli ونظرية DEMOIVRE-LAPLACE يكون في تمثيلهم للتقارب. فنظرية BERNOLLI بمفردها تشير إلى

التقارب في الإحتمال المناسب لسلسلة الحوادث  $\left| \frac{a_n}{n} - P \right| < \varepsilon$  بينما تشير

نظرية DEMOIVRE-LAPLACE إلى التقارب في الإحتمال المناسب مع سلسلة خاصة من الحوادث. أي الحوادث ذات الشكل  $(Z \leq z)$  والتي تعرف دالة التوزيع  $F(z)$ . وللتفريق بينهما نسمي الأولى التقارب بالإحتمال "Convergence in Probability" والثانية التقارب بالتوزيع "Convergence in Distribution" حيث سنتطرق إليهما بالتفصيل فيما يأتي.

<sup>1</sup>- Aris SPANOS: "Statistical fondation of Econometric Modelling" Cambrige University Press 1986. Page 166.

## 5-1-2 التقارب بالاحتمال

كما ذكرنا من قبل، فإنه لمعرفة التقارب بالاحتمال نحتاج إلى معرفة مفهوم السلسلة العشوائية، حيث أن هذه الأخيرة هي عبارة عن سلسلة من المتغيرات العشوائية، و التي تعتمد بطريقة ما على حجم العينة  $n$ . و كمثال على ذلك هو وسط العينة للملاحظات  $y_1, \dots, y_n$  حيث كلما ترتفع  $n$  فإن وسط العينة يتغير ومنه فإن  $\bar{y}_1, \dots, \bar{y}_n$  هي سلسلة عشوائية. و في مثالنا هذا تكون هذه السلسلة عبارة عن سلسلة متوسطات العينة. و منه فإن مشاكل التقارب هي عادة ماتهتم بتصرفات السلسلة لمايوول  $n$  إلى ما لانهاية كما أسلفنا ذكره من قبل.

لنجعل  $a_n$  تمثل سلسلة من المتغيرات العشوائية السلمية، نقول عن السلسلة العشوائية  $a_n$  بأنها تتقارب احتماليا إلى العدد الثابت  $a$  إذا كانت من أجل  $\varepsilon > 0$  "مهما كان صغيرا" فإن:

$$\lim_{n \rightarrow \infty} P_r[|a_n - a| > \varepsilon] = 0$$

أو

$$\lim_{n \rightarrow \infty} P_r[|a_n - a| < \varepsilon] = 1 \quad \dots\dots\dots (5.3)$$

و هناك طريقتان لتمثيل العبارة أعلاه:

$$a_n \xrightarrow{P} a \quad \text{إما}$$

$$P \lim(a_n) = a \quad \text{أو}$$

و ليكن تعريف التقارب بالاحتمال لمتغير عشوائي  $a$  بأنه تقارب نحو الصفر "0" للسلسلة  $a_n - a$ . حيث أن  $P \lim(!)$  هي نهاية الاحتمال. إذا كانت  $a_n$  هي سلسلة موجّهات عشوائية أو سلسلة مصفوفات عشوائية، فإن التعريف أعلاه ينطبق على كل عنصر من عناصر الموجه أو المصفوفة المذكورة. وفي حالة ما إذا كانت  $\bar{a}_n$  هي سلسلة مقدرات، فإن التقارب بالاحتمال إلى القيمة الحقيقية للمعلمة يعني أن ذلك المقدر هو مقدر متسق. وينطبق كذلك هذا التعريف على موجّهات ومصفوفات المقدرات.



إن المتراجحة  $|a_n - a| > \varepsilon$  يمكن أن تكون صحيحة أو غير صحيحة. احتمال صحتها محدد بواسطة دالة توزيع معينة. ولتكن  $F_n(!)$  تتقارب لـ  $a_n$  بواسطة  $a$  وكذلك  $\varepsilon$ . ومنه بمعرفة  $a$  وسلسلة التوزيعات المعينة، يشكل هذا الاحتمال سلسلة من النوع  $a_1(\varepsilon), a_2(\varepsilon), \dots, a_n(\varepsilon)$  والمعتمد وسطيا على  $\varepsilon$ . بالتالي فإن التعريف بالمعادلة (3.5) يعني أن سلسلة المتغيرات العشوائية  $a_1, a_2, \dots, a_n$  تتقارب احتماليا إلى العدد الثابت  $a$  إذا كانت نهاية السلسلة من الاحتمالات مساوية للصفر مهما كانت القيمة الموجبة  $\varepsilon$ . وكمثال عن التقارب بالاحتمال إلى عدد ثابت، نعتبر وسط العينة  $\bar{X}_n = \frac{1}{n} \sum X_i$  لعينة عشوائية  $(X_1, X_2, \dots, X_n)$  من أي مجتمع ذو وسط نهائي  $\mu$  وتباين  $\sigma^2$ .

نعرف أن توزيع  $\bar{X}_n$  له وسط  $\mu$  وتباين  $\frac{\sigma^2}{n}$ ، ويكون ذلك كافيا لضمان أن سلسلة المتغيرات العشوائية  $(\bar{X}_1, \bar{X}_2, \dots, \bar{X}_n)$  تتقارب احتماليا إلى وسط المجتمع  $\mu$ . وأبسط برهان على ذلك هو متراجحة Cheby Shev. إن أحد الأسباب الرئيسية لاستعمال التقارب الاحتمالي هو أن الصيغة  $\text{plim}(\cdot)$  لها بعض الخصائص غير موجودة في صيغة التقدير  $E(\cdot)$ . وهذا يساعدنا نسبيا للحصول على نتائج مرضية بإدخال النهايات الاحتمالية في الحالات التي يتعذر فيها استعمال صيغة التقدير  $E(\cdot)$ . ومن خصائص نهاية الاحتمال نذكر:

(a) إذا كان لدينا  $\text{plim}(a_n) = a$  و  $g(\cdot)$  هي دالة مستمرة. وكان قانون تعريف  $g(\cdot)$  لا يحتوي على  $n$  فإن:

$$a_n \xrightarrow{P} a \Rightarrow g(a_n) \xrightarrow{P} g(a) \\ \text{Plim}[g(a_n)] = g(a) \quad \text{أو}$$

(b) إذا كانت  $a_n$  و  $b_n$  سلسلتين عشوائيتين بحيث أن  $\text{plim}(a_n)$  و  $\text{plim}(b_n)$  موجودتان، فإن:



- \*  $P \lim(a_n + b_n) = P \lim(a_n) + P \lim(b_n)$
- \*  $P \lim(a_n - b_n) = P \lim(a_n) - P \lim(b_n)$
- \*  $P \lim(a_n \cdot b_n) = P \lim(a_n) \cdot P \lim(b_n)$
- \*  $P \lim(a_n / b_n) = P \lim(a_n) / P \lim(b_n)$

بشرط:  $P \lim(b_n) \neq 0$

$$* P \lim(a_n^2) = (P \lim a_n)^2$$

$$* P \lim(a_n^{-1}) = (P \lim a_n)^{-1}$$

حيث أن  $P \lim(a_n) \neq 0$

لندخل نتيجتين مهمتين في إستنتاج وجود النهايات الإحتمالية على بعض الحالات الخاصة وهما نظرية KHINTCHINE وقاعدة CHEBYSHEV.

### 3-1-5 نظرية KHINTCHINE

إذا كانت  $V_1, \dots, V_n$  سلسلة متغيرات عشوائية مستقلة ومتماثلة التوزيع (iid)، بوسط نهائي معروف  $\mu$  ثم أن وسط العينة  $\bar{V}_n$  يتقارب إحتماليا إلى  $\mu$  لما  $n \rightarrow \infty$ ، نقول أنه من أجل  $\varepsilon > 0$  مهما كان صغيرا، فإن:

$$\lim_{n \rightarrow \infty} \Pr \left[ \left| \frac{1}{n} \sum_{i=1}^n V_i - \mu \right| < \varepsilon \right] = 1 \quad \dots\dots (5.4)$$

وفي ظل شروط المعادلة (4.5) نكتب  $P \lim(\bar{V}_n) = \mu$ ، أو على شكل:  
 $P \lim(\bar{V}) = \mu$

### CHEBYSHEV قاعدة 4-1-5

إذا كانت  $a_n$  عبارة عن سلسلة متغيرات عشوائية، بحيث أنه كلما  $n \rightarrow \infty$  فإن:

$$i) \quad \text{Lim}[E(a_n)] = a$$

$$ii) \quad \text{Lim}[\text{var}(a_n)] = 0$$

هذا يستلزم أن:

$$P \lim(a_n) = a$$

ويمكن البرهنة على ذلك باستعمال متراجحة CHEBYSHEV. حيث تبين المتراجحة (المذكورة في المعادلة 3.5) بأنه إذا كانت  $a_n$  متغيرة عشوائية بوسط  $\mu$  وإنحراف معياري  $\sigma$  فإن:

$$\Pr[|a_n - a| \geq k\sigma] \leq \frac{1}{k^2} \quad \forall k > 0$$

$$\Pr[|a_n - a| < k\sigma] > 1 - \frac{1}{k^2} \quad \text{أو تكافؤ:}$$

حيث  $k$  ثابت. أي أنه من أجل  $\varepsilon > 0$ ،  $\sigma > 0$  و مهما كان صغيرهما فإن:

$$\Pr[|a_n - a| < \varepsilon] > (1 - \delta)$$

البرهان:

- لنجعل  $\delta = \frac{1}{k^2}$  ونطبق هذه المتراجحة لنجد:

$$\Pr[|a_n - E(a_n)| < \delta^{-1/2} (\text{var}(a_n))^{1/2}] > 1 - \delta$$

إن الشرط الأول (i) يبين بأنه من أجل أي  $\varepsilon > 0$  مهما كان صغيرا تكون القيمة

$$n \rightarrow \infty \quad E|a_n - a| < \varepsilon$$

أما الشرط الثاني (ii) فيبين بأنه من أجل أي قيمة  $\lambda > 0$  مهما كانت صغيرة، تكون القيمة (المقدار):

$$|\text{var}(a_n)| < \lambda$$

$$\text{أو } [\text{var}(a_n)]^{1/2} < \lambda^{1/2}$$

وذلك لما تكون  $n$  كبيرة (أي  $n \rightarrow \infty$ ).

ثم نستعمل المتراجحة:  $|a_n - a| \leq |a_n - E(a_n)| + |E(a_n) - a|$   
 كذلك نستخلص من الشرط (i) بأنه من أجل أي  $\varepsilon_1$  و  $n$  كبيرة فإن:

$$|a_n - a| < |a_n - E(a_n)| + \varepsilon_1$$

$$|a_n - E(a_n)| < \delta^{-1/2} (\text{var}(a_n))^{1/2}$$

وإذا كانت:

نحصل على:

$$|a_n - a| < \delta^{-1/2} [\text{var}(a_n)]^{1/2} + \varepsilon_1 \leq \delta^{-1/2} \cdot \lambda^{1/2} + \varepsilon_1$$

كذلك باستعمال الشرط (ii)، ويكون هذا من أجل أية قيمة لـ  $\varepsilon_1$ ،  $\lambda$  وكذلك  $n$  كبيرة.

- لما يكون  $\varepsilon_1$  و  $\lambda$  معطاة يمكن دائما اختيار  $\varepsilon_1$  و  $\lambda$  لنجعل:

$$\delta^{-1/2} \cdot \lambda^{1/2} + \varepsilon_1 = \varepsilon$$

وبالتالي نجد:

$$|a_n - a| < \varepsilon$$

وذلك كلما كانت العبارة:  $|a_n - E(a_n)| < \delta^{-1/2} [\text{var}(a_n)]^{1/2}$  تحت الشرطين (i) و (ii). إن هذه النتيجة الأخيرة لها احتمال أكبر من  $(1 - \delta)$  ونستلزم أن:

$$\Pr[|a_n - a| < \varepsilon] > 1 - \delta$$

ومنه نقول، بتطبيق قاعدة CHEBYSHEV، يمكن بسهولة إظهار أن الوسط  $\bar{a}_n$  لعينة الملاحظات  $n$ ، المأخوذة من المجتمع ذو وسط  $\mu$  والتباين  $\sigma^2$ ، يتقارب



إحتماليا إلى  $\mu$ . ومادام  $E(\bar{a}_n) = \mu$  و  $\text{var}(\bar{a}_n) = \frac{\sigma^2}{n}$  فإنه يستلزم بالشرطين (i)، (ii)، أن تكون  $\bar{a}_n$  متقاربة إحتماليا إلى  $\mu$ .

### 5-1-5 التقارب بالإحتمال إلى متغير عشوائي

يمكن توسيع مفهوم التقارب الإحتمالي في بعض الأحيان إلى الشكل التالي:

لنفرض أن السلسلة العشوائية  $a_n$  تحقق الشرط:

$$\text{Plim}(a_n - a) = 0$$

بحيث أن  $a$  ليس عددا ثابتا، وإنما هو متغير عشوائي بتوزيع لايعتمد على حجم العينة  $n$ ، يمكن تعريف ذلك على أنه تقارب إحتمالي إلى متغير عشوائي، ومنه يجب ملاحظة أنه في هذه الحالة  $\text{Plim}(a_n)$  لايساوي  $a$ ، وإنما الفرق  $(a_n - a)$  هو الذي يتقارب إحتماليا إلى العدد الثابت وهو الصفر.

### 6-1-5 التقارب الدائم و المؤكد : Almost Surely Convergence

يخضع التقارب الدائم والمؤكد للقانون القوي للأعداد الكبيرة (S.L.L.N) **Strong Law of Large Numbers** وأول نتيجة مرتبطة به في حالة ما إذا كانت  $a_n$  سلسلة من متغيرات برنولي الموزعة عشوائيا برهنت من طرف BOREL (1909)، حيث تشير نظرية BOREL أنه إذا كانت  $\{a_i\}$  هي متغيرات برنولي العشوائية المستقلة و المتماثلة التوزيع مع

$$\text{Pr}(a_i = 1) = P \text{ و } \text{Pr}(a_i = 0) = 1 - P \text{ من أجل كل } i \text{ فإن:}$$

$$\Pr\left[\lim_{n \rightarrow \infty} \frac{a_n}{n} = P\right] = 1 \dots\dots(5.5)$$

أو

$$\lim_{n \rightarrow \infty} \Pr\left[\max_{m \geq n} \left|\frac{a_m}{m} - P\right| \geq \varepsilon\right] = 0 \dots\dots(5.6)$$

ومنه تكون العلاقة ما بين القانون القوي للأعداد الكبيرة (المذكورة بالمعادلة (6.5)) والقانون الضعيف للأعداد الكبيرة (والمذكورة بالمعادلة (1.5)) على الشكل:

$$\left|\frac{a_n}{n} - P\right| \leq \max_{m \geq n} \left|\frac{a_m}{m} - P\right| \dots\dots(5.7)$$

ومنه يستلزم أن التقارب الدائم والمؤكد يعني التقارب بالإحتمال والعكس ليس صحيحا.

### 7-1-5 نظرية KOLMOGOROV

لتكن سلسلة المتغيرات العشوائية والمستقلة  $\{a_n; n \geq 1\}$ ، بحيث أنه يوجد  $E(a_i)$  و  $\text{var}(a_i)$  من أجل كل  $i$  ( $i = 1, 2, \dots, n$ ) فإذا تحقق الشرطان:

$$i) \lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{k=1}^n \text{var}(a_k) = 0$$

$$ii) \sum_{k=1}^{\infty} \frac{1}{k^2} \text{var}(a_k) < \infty$$

فإنه يمكن كتابة:

$$\Pr\left[\lim_{n \rightarrow \infty} \frac{1}{n} \left(\sum_{i=1}^n [a_i - E(a_i)]\right) = 0\right] = 1 \dots\dots(5.8)$$

إن هذا القانون القوي للأعداد الكبيرة (S.L.LN) متكافئ مع القانون الضعيف للأعداد الكبيرة (W.L.L.N) والمذكورة من طرف CHEBYSHEV.

إذا كانت  $a_1, a_2, \dots, a_n$  سلسلة متغيرات عشوائية ومستقلة بحيث أن:  $\text{var}(a_i) = \sigma_i^2 < \infty$ ، ثم من أجل أي  $\varepsilon > 0$  فإن:

$$\Pr \left[ \max_{1 \leq k \leq n} |a_k - E(a_k)| \geq \varepsilon \right] \leq \frac{1}{\varepsilon^2} \sum_{i=1}^n \sigma_i^2 \dots (5.9)$$

ويذهب KOLMOGOROV إلى البرهنة بأنه في حالة ما إذا كانت  $[a_n, n \geq 1]$  سلسلة متغيرات عشوائية مستقلة ومتماثلة التوزيع بحيث  $E(a_i) < \infty$  فإن:

$$\sum_{k=1}^{\infty} \frac{\text{var}(a_k)}{k^2} = \sum_{k=1}^{\infty} \frac{1}{k^2} \int_{-k}^{+k} x^2 f(x) dx < \infty \dots (5.10)$$

والتي تعني وتستلزم أنه من أجل سلسلة ما فإن وجود التوقع يعتبر شرطاً ضرورياً وفي نفس الوقت كافياً للقانون القوي للأعداد الكبيرة، ومنه نقول أنه في حالة متغيرات عشوائية مستقلة ومتماثلة التوزيع، إذا كانت  $\text{var}(a_i) = \sigma^2$  من أجل  $i$  فإن:

$$\text{var}(a_n) = n\sigma^2 = O(n) \dots (5.11)$$

في حالة متغيرات عشوائية مستقلة مع  $\text{var}(a_i) = \sigma_i^2 < \infty$   $i=1, 2, \dots, n$  فإن:

$$\text{var}(a_n) = \sum_{i=1}^n \sigma_i^2 = O(n) \dots (5.12)$$

ويمكن كتابة شرط MARKOV<sup>(2)</sup> على الشكل:

$$\text{var}(a_n) = O(n^2) \dots (5.13)$$

حيث نقرأ (0) لأصغر درجة من "of smaler Order than" و نصل إلى نفس الأثر مادام:

$$\text{var}(a_n) = O(n) \Rightarrow \text{var}(a_n) = O(n^2) \dots (5.14)$$

<sup>2</sup>- Aris SPANOS. page 171 (مرجع سابق)



إن شرط KOLMOGOROV هو شكل مقيد أكثر من شرط MARKOV، متطلبا أن يكون تباين المجاميع الجزئية دائما من الدرجة  $n$  وبانتظام.

### 5-1-5 نهاية التوزيعات: التقارب بالتوزيع: Convergence in Distribution

يعني الإتساق Consistency أن هناك احتمال عالي لأن يكون خطأ المعاينة صغيرا عندما تكون العينة كبيرة بشكل كاف. ولايقترح هذا المفهوم توضيحا حول خطأ المعاينة مثل الخطأ المعياري. ولهذا الهدف يجب أن نوسع التحليل ومنه نعود إلى سلسلة المتغيرات العشوائية  $a_1, a_2, \dots, a_n$  مع دوال توزيعها  $F_1(.), F_2(.), \dots, F_n(.)$ . نقول عن هذه الدوال التوزيعية  $F_i(.)$  بأنها تتقارب بالتوزيع إلى متغير عشوائي ما. مع دالة التوزيع  $F(.)$  إذا تقاربت  $F_n(.)$  إلى  $F(.)$  لما  $n \rightarrow \infty$  عند كل النقاط المستمرة لـ  $F(.)$ .

إن التوزيع  $F(.)$  يسمى بالنهاية التوزيعية لهذه السلسلة من المتغيرات العشوائية  $a_n$ . ونلاحظ أن هذا التعريف يحتوي كحالة خاصة على التقارب الإحتمالي إلى العدد الثابت. ومنه نقول إذا كانت  $a$  عبارة عن متغير عشوائي له الدالة التوزيعية  $F(.)$ ، فإن  $a_n$  تتقارب بالتوزيع إلى  $a$  عندما  $\lim_{n \rightarrow \infty} F_n(a) = F(a)$  وفي حالة متغيرات منقطعة  $P(X_n = x) \rightarrow P(X = x)$ .

- مثال:

لنفرض أن  $\eta$  هي متغير عشوائي موزع مثل:  $\eta \sim N(0, Q)$  وأنه لما  $n \rightarrow \infty$  فإن السلسلة  $a_n$  تتقارب توزيعيا إلى  $\eta$ . ويمكن أن نكتب هذا على الشكل:

$$a_n \xrightarrow{D} \eta \sim N(0, Q)$$

ونقول إذا كانت  $a_i$  لها دالة كثافة  $f_i(.)$  ( $i = 1, 2, \dots, n$ ) وكذلك  $a$  لها دالة كثافة  $f(.)$ ، فإن التقارب بالتوزيع إلى  $a$  أو إلى  $f(.)$  يعني أنه من أجل كل

$$\lim_{n \rightarrow \infty} \Pr[A \leq a_n \leq B] = \int_A^B f(s) ds \quad \text{فإن } A \leq B \text{ مع } A \text{ و } B$$

وهناك إرتباط قوي بين التقارب بالتوزيع وتقارب الدوال المميزة.

وإذا كنا مهتمين بدراسة التقارب بالتوزيع إلى التوزيع الطبيعي، مثلا، فإن أبسط وسيلة لإثبات التقارب بالتوزيع هي الإستعانة أو إستعمال الدالة المميزة، حيث أن الدالة المميزة لمتغير عشوائي  $a$  تعرف كما يلي:

$$Q_a(t) = E(e^{ita}) = \int_{-\infty}^{+\infty} e^{ita} f(a) da$$

$$Q_a(t) = E(e^{ita}) = E\left[1 + ita + \frac{1}{2!}(it)^2 a^2 + \frac{1}{3!}(it)^3 a^3 + \dots\right]$$

$$Q_a(t) = E(e^{ita}) = \left[1 + it(Ea) - \frac{1}{2!}t^2(Ea^2) - \frac{1}{3!}it^3(Ea^3) + \dots\right]$$

حيث:  $i = \sqrt{-1}$

إن النظرية المهمة. في تحديد نهاية التوزيع لسلسلة متغيرات عشوائية  $a_1, a_2, \dots, a_n$  والمعتمدة على الدالة المميزة هي أننا نتأكد من أن الدالة المميزة  $Q_n(t)$  تتقارب إلى الدالة  $Q(t)$  لما  $n \rightarrow \infty$  من أجل كل  $t$ ، ثم نتأكد من إستمرارية  $Q(t)$  عند النقطة  $t = 0$ ، بعدها نحاول التعرف على التوزيع الذي له  $Q(t)$  كدالة مميزة. إن ذلك التوزيع هو نهاية التوزيع للسلسلة  $a_1, a_2, \dots, a_n$  ويسمى بالتقارب بالتوزيع.

في الدالة المميزة  $Q_a(t)$  أعلاه قمنا بتوسيع  $e^{ita}$  إلى سلسلة لامتناهية، ومنه إذا فاضلنا  $Q_a(t)$  بالنسبة لـ  $t$ ، المشتق من الدرجة  $k$ ، عند النقطة  $t = 0$  سيكون  $i^k (Ea^k)$ . وهناك عدة خصائص للدالة المميزة.

(a) تحدد الدالة المميزة لوحدها نوع التوزيع.

(b) إذا كانت سلسلة الدوال المميزة  $Q_n(t)$  تتقارب إلى الدالة المميزة  $Q(t)$ ، فإن سلسلة الدوال التوزيعية المناسبة لها تتقارب إلى الدالة التوزيعية المحددة بواسطة  $Q(t)$ .



(c) إذا كانت  $a_1$  و  $a_2$  مستقلتين ولهما الدالتين المميزتين  $Q_1(t)$ ،  $Q_2(t)$  على التوالي، فإن الدالة المميزة لـ  $a_1 + a_2$  هي  $Q_1(t) \cdot Q_2(t)$ .  
(d) إذا كانت  $Q(t)$  هي الدالة المميزة لـ  $a$ ، فإن  $Q(t/k)$  هي الدالة المميزة لـ  $a/k$ .

إذا كان  $a$  موجه عشوائي ذو بعد  $(P \times 1)$ ، فإن الدالة المميزة له:

$$Q_a(t) = E(e^{ita}) = E\left[e^{(t_1 a_1 + t_2 a_2 + \dots + t_p a_p)}\right]$$

حيث أن  $t$  هو موجه غير عشوائي بنفس أبعاد الموجه العشوائي  $a$ . إن الخصائص الأربعة المذكورة أعلاه حول الدالة المميزة تطبق بنفس الطريقة في حالة الموجهات والمصفوفات.

ولنبحث الآن عن الدالة المميزة للموجه  $a$  الذي له وسط  $\mu$  ومصفوفة تباين مشترك هي  $\Sigma$ ، أي:  $a \sim N(\mu, \Sigma)$  . . . . .

$$Q_a(t) = E(e^{ita}) = \int_{-\infty}^{+\infty} (2\pi)^{-k/2} |\Sigma|^{-1/2} \cdot \exp\left[-\frac{1}{2}(Z - \mu)' \Sigma^{-1}(Z - \mu) + iZ't\right] dZ$$

$$Q_a(t) = \exp\left[i\mu't - \frac{1}{2}t' \Sigma^{-1} t\right] \quad (3)$$

وهي الدالة المميزة لموجه المتغيرات الطبيعية. أما الدالة المميزة للمتغير الطبيعي المعياري هي:

$$Q_a(t) = e^{-t^2/2}$$



## 9-1-5 نظرية النهاية المركزية The Central Limit Theorem

لتكن  $a_1, a_2, \dots, a_n$  سلسلة متغيرات عشوائية مستقلة ومتماثلة التوزيع بوسط  $\mu$ ، وتباين  $\sigma^2$ . ولتكن  $\bar{a}_n$  هي وسط العينة  $n$ . ومنه فإن  $\sqrt{n}(\bar{a}_n - \mu)/\sigma$  تتقارب بالتوزيع إلى التوزيع الطبيعي المعياري.

ولإثبات ذلك نقول، لتكن  $Q(t)$  هي الدالة المميزة لكل  $a_i - \mu = y$  مثلا. وتكون المشتقتين الأولى والثانية لـ  $Q(t)$  على الشكل:

$$Q'(t) = E\left(\frac{de^{ity}}{dt}\right) = E(iye^{ity})$$

$$Q''(t) = E(iy)^2 \cdot e^{ity} = -E[y^2 \cdot e^{ity}]$$

ونظرا إلى أن  $e^{ity} = \cos ty + i \sin ty$  لها نهاية وكذلك المقداران  $E(y)$  و  $E(y^2)$  موجودان، فإن المشتقتين أعلاه، موجودتين ومستمرتين.

وباستعمال الخاصية القائلة بأنه إذا كانت الدالة المميزة  $Q(t)$  مستمرة عند الدرجة  $m$  من الاشتقاق في جوار الصفر فإن:

$$Q(t) = Q(0) + Q'(0)t + \frac{Q''(0)}{2}t^2 + \dots + \frac{Q^{(m)}(0)}{m!}t^m + o(t^m)$$

لتكون الدالة المميزة لـ  $y$  على الشكل:

$$Q(t) = 1 + i(Ey)t - \frac{E(y^2)}{2}t^2 + o(t^2) = 1 - \frac{\sigma^2 t^2}{2} + o(t^2) \quad (4)$$

ويعتبر تطبيق الخاصية (d) للدوال المميزة تكون الدالة المميزة لـ

$$\frac{\sqrt{ny}}{\sigma} = \sqrt{n}(a_i - \mu)/\sigma \text{ هي:}$$

$$Q\left(\frac{t}{\sqrt{n}\sigma}\right) = 1 - \frac{t^2}{n} + o\left(\frac{t^2}{n}\right)$$

4- أنظر دائما: Theil chap2 (مرجع سابق)

حيث أن  $Z = 0(a)$  تعني أن  $\frac{Z}{a} \rightarrow 0$  وكذلك تكون  $Z = 0(t^2/n)$  إذا وفقط إذا كانت  $Z = 0(t^2/\sigma^2 n)$  من أجل أي قيمة لـ  $\sigma^2$  تختلف عن الصفر. ثم أن المتغير العشوائي الذي نهتم به هو مجموع الحدود المستقلة  $n$ :

$$\sum_{i=1}^n \frac{a_i - \mu}{\sigma \sqrt{n}} = \sqrt{n} \sum_{i=1}^n \frac{a_i - \mu}{n\sigma} = \sqrt{n} \frac{(\bar{a}_n - \mu)}{\sigma} \dots (5.15)$$

وباستعمال الخاصية (c) للدوال المميزة يعطي هذا المجموع الدالة المميزة التالية:

$$Q_n(t) = \left[ 1 - \frac{t^2}{2n} + 0.\left(\frac{t^2}{n}\right) \right]^n$$

وبإدخال اللوغاريتم الطبيعي وتطبيق توسيعات "تايلور" المعروفة  $\log(1+Z) \approx Z$  من أجل  $|Z|$  صغيرة يكون:

$$\log Q_n(t) = n \log \left[ 1 - \frac{t^2}{2n} + 0.(n^{-1}) \right] \rightarrow -\frac{t^2}{2}$$

$$= n \log \left[ 1 - \frac{t^2}{2n} + 0(n^{-1/2}) \right] \approx n \left[ -\frac{t^2}{2n} \right]$$

ولما  $n \rightarrow \infty$  فإن:

$$\log Q_n(t) = -\frac{t^2}{2} \Rightarrow Q_n(t) \approx +e^{-t^2/2}$$

ونستخلص أنه لما  $n \rightarrow \infty$ ، فإن الدالة المميزة  $Q_n(t)$  للمتغير

العشوائي في المعادلة (5.5) تتقارب، من أجل كل  $t$ ، إلى  $e^{-t^2/2}$  والتي هي الدالة المميزة للتوزيع الطبيعي المعياري.

لاحظ أن  $e^{-t^2/2}$  مستمرة عند النقطة  $t = 0$ ، وهي جزء من الشرط

المذكور أعلاه. ومنه نقول لما تكون  $a_n$  سلسلة متغيرات عشوائية تتبع التوزيع الطبيعي يمكن كتابته:



$$a_n \xrightarrow{D} \eta \sim N(0, Q) \dots (5.16)$$

أو:

$$a_n \rightarrow N(0, Q) \dots (5.17)$$

$$a_n^A \sim N(0, Q)$$

أو

### 10-1-5 خصائص التقارب بالإحتمال والتقارب بالتوزيع:

هناك عدة خصائص للتقارب بالإحتمال والتقارب بالتوزيع، هي:

(1) لتكن  $[a_n, b_n]$ ،  $n = 1, 2, \dots$  سلسلتين من المتغيرات العشوائية، إذا تقاربت  $a_n - b_n$  إحصائيا إلى الصفر ( $\text{plim}(a_n - b_n) = 0$ ) وكانت  $b_n$  لها نهاية توزيع (أي  $b_n$  تتقارب بالتوزيع إلى متغير عشوائي  $b$ ). فإن  $a_n$  لها كذلك نهاية توزيع (أي  $a_n$  تتقارب بالتوزيع إلى  $b$ ). ومنه فإن هاتين النهايتين التوزيعيتين متماثلتين.

(2) لنفرض أن  $b_n$  لها نهاية توزيع هو  $b$  و  $a_n$  لها نهاية إحصائية مساوية للصفر ( $\text{plim}(a_n) = 0$ )، فإن حاصل ضرب السلسلتين والمساوي للسلسلة  $a_1 b_1, a_2 b_2, \dots, a_n b_n$  يكون كذلك له نهاية إحصائية مساوية للصفر أي:

$$\text{plim}(a_n b_n) = 0$$

(3) لنفرض أن  $b_n$  تتقارب بالتوزيع إلى المتغير العشوائي  $b$ ، و  $a_n$  تتقارب بالإحتمال إلى العدد الثابت (ليس بالضرورة أن يكون صفرا) أي  $\text{Plim}(a_n) = a$  حيث  $a$  ثابت، فإن مجموع السلسلتين  $a_n + b_n$  يتقارب بالتوزيع إلى  $a + b$  أي:

$$a_n + b_n \xrightarrow{D} a + b$$

بينما حاصل الضرب  $a_n b_n$  يتقارب بالتوزيع إلى  $ab$ ، أي:

$$a_n b_n \xrightarrow{D} ab$$

أما حاصل القسمة  $b_n / a_n$  فيتقارب بالتوزيع إلى  $b/a$  حيث  $a \neq 0$ ، أي:



$$(b_n/a_n) \xrightarrow{D} b/a$$

(4) إذا كانت  $g(\cdot)$  دالة مستمرة وكانت  $a_n$  تتقارب بالتوزيع إلى  $a$ ، فإن  $g(a_n)$  تتقارب بالتوزيع إلى  $g(a)$ ، حيث أن قانون تعريف  $g(\cdot)$  لا يحتوي على  $n$ ، أي أن:

$$a_n \xrightarrow{D} a \Rightarrow g(a_n) \xrightarrow{D} g(a)$$

(5) إذا كانت  $g(\cdot)$  دالة مستمرة وقانون تعريفها لا يعتمد على  $n$ ، وكانت  $a_n - b_n$  تتقارب بالإحتمال إلى الصفر ( $\text{plim}(a_n - b_n) = 0$ )، و  $a_n$  تتقارب بالتوزيع إلى  $a$  ( $a_n \xrightarrow{D} a$ )، فإن  $g(a_n) - g(b_n)$  تتقارب بالإحتمال إلى الصفر، أي:

$$a_n \xrightarrow{D} a, \text{plim}(a_n - b_n) = 0 \Rightarrow \text{plim}[g(a_n) - g(b_n)] = 0$$

ونلاحظ أن هذه القوانين تبقى سارية المفعول لما تكون  $a_n$ ،  $b_n$  سلاسل موجهات أو مصفوفات عشوائية ولما تكون  $g(\cdot)$  دالة موجه أو دالة مصفوفة. حيث إذا كانت مثلا  $A_n$  سلسلة مصفوفات بحيث  $\text{plim}(A_n) = A$  و  $b_n$  سلسلة موجهات بحيث أن:  $b_n \xrightarrow{D} b \sim N(0, Q)$  فإن:

$$A_n b_n \xrightarrow{D} Ab \sim N(0, AQA') \dots (5.18)$$

## 5-2 المربعات الصغرى في العينات الكبيرة:

في دراسة توزيع المعاينة لمقدر المربعات الصغرى، أشرنا من قبل أنه لما يكون  $u_i$  موزعا طبيعيا فإن توزيع المعاينة لـ  $\hat{\beta}$  يكون كذلك طبيعيا. حتى وإن لم يكن  $u_i$  طبيعيا، ولكن له تباينات محددة (نهائية). يكون توزيع المعاينة لـ  $\hat{\beta}$  تقريبا طبيعيا. وذلك حسب نظرية النهاية المركزية. لنسقط الآن فرضية التوزيع الطبيعي وندرس توزيع  $\hat{\beta}$  لما يزداد حجم العينة  $n$  ثم نتساءل هل يقترب المتغير العشوائي  $\hat{\beta}$  من  $\beta$  باحتمال عال لما تزداد  $n$ ؟ وتحت أية شروط يكون توزيع المعاينة لـ  $\hat{\beta}$  أقرب إلى التوزيع الطبيعي كلما ازداد حجم  $n$ ؟ وبعبارة أخرى هل  $\hat{\beta}_n$  (والمعتمد على  $n$  ملاحظات) يتقارب بالاحتمال إلى  $\beta$ ؟ ومتى يتقارب  $\hat{\beta}_n$  بالتوزيع إلى التوزيع الطبيعي؟

إن الإجابة عن كل هذه الأسئلة تعود بنا لمشكل التقارب بالاحتمال والتقارب بالتوزيع المذكورين سابقا، ولناخذ النموذج الخطي العام:

$$Y = XB + U$$

مع  $X$  غير عشوائية والأخطاء  $u_i$  مستقلة ومتماثلة التوزيع.

$$u_i \sim iid(0, \sigma_u^2) \quad i = 1, 2, \dots, n$$

ومنه يكون مقدر المربعات الصغرى العادية هو:

$$\hat{\beta} = (X'X)^{-1} X'Y$$

وتحت الشروط المذكورة أعلاه يكون مقدر المربعات الصغرى العادية  $\hat{\beta}$  محتفظا بخاصية أفضل مقدر خطي غير متحيز BLUE. إن الفرضية أو الخاصية الوحيدة الناقصة هنا هي التي تعني التوزيع الطبيعي. حيث:

$$E(\hat{\beta}) = \beta, \quad \text{var}(\hat{\beta}) = \sigma_u^2 (X'X)^{-1}$$

وبناء على إختفاء خاصية التوزيع الطبيعي. فإن توزيع المتغير العشوائي  $\hat{\beta}$  يكون

غير معروف ويمكن إظهار أن  $\lim_{n \rightarrow \infty} [\text{var}(\hat{\beta})] = 0$  لما يذهب حجم العينة  $n$  إلى ما لا نهاية، ومن ثم بإستعمال قاعدة CHEBYSHEV يكون  $\hat{\beta}$  مقدر المربعات الصغرى المتسق لـ  $\beta$  <sup>(5)</sup>. وللتأكد من أن  $\text{var}(\hat{\beta})$  تنتهي إلى الصفر كلما ارتفع حجم العينة  $n$ ، نحتاج إلى بعض الفرضيات حول التصرف النهائي لغزوم العينة في المتغيرات  $X$ ، ونكتب:

$$\lim_{n \rightarrow \infty} (n^{-1} X'X) = Q \dots (5.19)$$

حيث  $Q$  مصفوفة غير شاذة.

$$\lim_{n \rightarrow \infty} (n^{-1} X'X) \rightarrow Q \Rightarrow \lim_{n \rightarrow \infty} (n^{-1} X'X)^{-1} \rightarrow Q^{-1}$$

ومنه نجد:

$$\lim_{n \rightarrow \infty} [\text{var}(\hat{\beta})] = \lim_{n \rightarrow \infty} (n^{-1} \sigma_u^2 (n^{-1} (X'X)^{-1})) \rightarrow 0. Q^{-1} = 0$$

ومنه نقول عن مقدر ما بأنه متسق إذا حقق الشرطين:

$$i) \lim_{n \rightarrow \infty} E(\hat{\beta}) = \beta$$

$$ii) P \lim [\text{var}(\hat{\beta})] = 0$$

### 1-2-5 إتساق $\hat{\sigma}_u^2$ :

إذا كان  $\hat{\beta}$  هو مقدر المربعات الصغرى المتسق لـ  $\beta$ ، فمن البديهي أن يكون  $\hat{\sigma}_u^2$  مقدر متسق لـ  $\sigma_u^2$  حيث أن:

$$\hat{U} = Y - X\hat{\beta} = -X(\hat{\beta} - \beta) + U$$

$$\hat{U} - U = -X(\hat{\beta} - \beta)$$

<sup>5</sup>- فروخي جمال: "نظرية الإقتصاد القياسي" ديوان المطبوعات الجامعية، 1993، ص 152-153.



وإذا كانت  $X$  غير عشوائية و  $\hat{\beta}$  مقدار متسق لـ  $\beta$  فإن كل عنصر من  $(\hat{u}_i - u_i)$  يتقارب بالإحتمال إلى الصفر.

$$(\hat{u}_i - u_i) \xrightarrow{P} 0$$

وهذا يعني أن  $\hat{u}_i$  يتقارب إحصائيا إلى المتغير العشوائي  $u_i$ . فالتصرف النهائي لـ  $\hat{\sigma}_u^2 = \sum \hat{u}_i^2 / (n - k)$  يكافئ التصرف النهائي لـ  $\sum u_i^2 / (n - k)$  وهو مستقل ومتماثل التوزيع بتباين  $E(u_i^2) = \sigma_u^2$ ، ومنه بواسطة نظرية KHINTCHINE تصبح:

$$P \lim \left( \frac{\sum u_i^2}{n} \right) = \sigma_u^2$$

ومنه يكون  $\hat{\sigma}_u^2$  مقدار  $\sigma_u^2$  المتسق.

### 2-2-5 توزيع $\hat{\beta}$ في العينات الكبيرة

لدينا النموذج الخطي العام  $Y = X\beta + U$  مع  $X$  غير عشوائية وكذلك  $u_i$  مستقلة ومتماثلة التوزيع  $u_i \sim iid(0, \sigma_u^2)$ ، ثم لدينا:

$$\text{var}(X'U) = \sigma_u^2 X'X \dots (5.20)$$

وكذلك:

$$\text{var}(n^{-1/2} \cdot X'U) = \sigma_u^2 (n^{-1} X'X) \dots (5.21)$$

وبمعرفة المعادلة (النتيجة) (19.5) تصبح لدينا:

$$\lim_{n \rightarrow \infty} \text{var}(n^{-1/2} X'U) = \sigma_u^2 Q \dots (5.22)$$

ومنه يمكن القول:

$$n^{-1/2} \cdot (X'U) \xrightarrow{D} \eta \sim N(0, \sigma_u^2 Q) \dots (5.23)$$

وباستعمال هذه النتيجة في تحليل  $\hat{\beta}$  نجد:

$$\hat{\beta} = (X'X)^{-1} X'Y = \beta + (X'X)^{-1} X'U$$

$$\sqrt{n}(\hat{\beta} - \beta) = (n^{-1}X'X)^{-1} \cdot (n^{-1/2}X'U)$$

لتصبح:

$$n^{-1/2} \cdot (X'U) \xrightarrow{D} \eta \sim N(0, \sigma_u^2 Q)$$

$$(n^{-1}X'X) \xrightarrow{P} Q \dots (5.24)$$

$$(n^{-1}X'X)^{-1} \xrightarrow{P} Q^{-1} \quad \text{أي:}$$

$$P \lim (n^{-1}X'X)^{-1} = Q^{-1} \dots (5.25)$$

وباستعمال المعادلة (18.5) تصبح:

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{D} \eta Q^{-1} \sim N(0, \sigma_u^2 Q^{-1} Q Q^{-1})$$

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{D} Q^{-1} \eta \sim N(0, \sigma_u^2 Q^{-1}) \dots (5.26)$$

ومنه في العينات الكبيرة:

$$\sqrt{n}(\hat{\beta} - \beta) \overset{A}{\sim} N(0, \sigma_u^2 Q^{-1})$$

$$(\hat{\beta} - \beta) \overset{A}{\sim} N(0, \sigma_u^2 n^{-1} Q^{-1}) \dots (5.27)$$

حيث تعني A تقاربيا Asymptotically

ومادامت Q هي نهاية السلسلة  $(n^{-1}X'X)$  و  $Q^{-1}$  هي نهاية السلسلة

$(n^{-1}X'X)^{-1}$  فإن عينة التقارب النهائية المناسبة لـ  $Q^{-1}$  هي  $n(X'X)^{-1}$

ومنه تصبح من أجل الأعداد الكبيرة:

$$\hat{\beta} \overset{A}{\sim} N(\beta, \sigma_u^2 (X'X)^{-1}) \dots (5.28)$$

### 3-2-5 القيود الخطية الدقيقة (الصحيحة)

لإختبار مجموعة من القيود الخطية في ظل العينات الكبيرة وتحت الشروط القوية للمربعات الصغرى، نقول أنه اعتمادا على تقارب مقدار المربعات الصغرى  $\hat{\beta}$  في المعادلة (28.5) تكون مجموعة القيود الخطية والمستقلة  $R\beta = r$  على الشكل:

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{D} Q^{-1}\eta \sim N(0, \sigma_u^2 Q^{-1})$$

وباستعمال المعادلة (18.5) تكون:

$$\sqrt{n}R(\hat{\beta} - \beta) \xrightarrow{D} RQ^{-1}\eta \sim N(0, \sigma_u^2 RQ^{-1}R')$$

$$\sqrt{n}(R\hat{\beta} - r) \xrightarrow{D} RQ^{-1}\eta \sim N(0, \sigma_u^2 RQ^{-1}R')$$

وتحت الفرضية  $H_0: R\beta = r$ ، تصبح:

$$n(R\hat{\beta} - r)'[\sigma_u^2 RQ^{-1}R']^{-1}(R\hat{\beta} - r) \xrightarrow{D} \chi^2 \sim \chi_m^2$$

$$n(R\hat{\beta} - r)'[RQ^{-1}R']^{-1}(R\hat{\beta} - r)/\sigma_u^2 \xrightarrow{D} \chi^2 \sim \chi_m^2 \dots (5.29)$$

$$(R\hat{\beta} - r)'[Rn^{-1}Q^{-1}R']^{-1}(R\hat{\beta} - r)/\sigma_u^2 \xrightarrow{D} \chi^2 \sim \chi_m^2$$

حيث  $m$  هي عدد القيود الخطية.

وتمثل العبارة (29.5) التقارب بالتوزيع إلى المتغير العشوائي  $\chi^2$  والذي له توزيع  $\chi^2$  بدرجات حرية  $m$ . وهو ما يبين كيفية الانتقال من التوزيع الطبيعي إلى التوزيع  $\chi^2$  بنفس الطريقة المذكورة في الفصل الثالث. في العينات الكبيرة تعوض المصفوفة  $Q^{-1}$  بالتقريب  $n(X'X)^{-1}$ .

$$(R\hat{\beta} - r)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)/\sigma_u^2 \xrightarrow{A} \chi_m^2: H_0: R\beta = r \dots (5.30)$$

ومن حديثنا بالفصل الثالث نعرف أن الصيغة التربيعية (30.5) هي عبارة

عن الفرق بين مجموع مربعات البواقي المقيدة (RRSS) وغير المقيدة (URSS) ومنه نقول:

$$(RRSS - URSS)/\sigma_u^2 \xrightarrow{A} \chi_m^2: H_0: R\beta = r \dots (5.31)$$



## 4-2-5 إتساق $\hat{\beta}$ لما تكون المصفوفة $X$ عشوائية

إذا إحتوت المصفوفة  $X$  على بعض الأعمدة التي تكون عشوائية، مع بقاء المصفوفة  $Q$  غير شاذة وبوجود الفرضيتين:

$$i) P \lim(n^{-1}X'X) = Q \dots\dots\dots (5.32)$$

$$ii) P \lim(n^{-1}X'U) = q = 0 \dots\dots\dots (5.33)$$

تكون النهاية الإحتمالية لمقدر المربعات الصغرى  $\hat{\beta}$  على الشكل:

$$\hat{\beta} = (X'X)^{-1}X'Y = \beta + (X'X)^{-1}X'U$$

$$\hat{\beta} = \beta + (n^{-1}X'X)^{-1}(n^{-1}X'U)$$

$$p \lim(\hat{\beta}) = \beta + p \lim(n^{-1}X'X)^{-1} p \lim(n^{-1}X'U) \\ = \beta + Q^{-1}q$$

وباعتبار  $q = 0$ ، فإن:

$$p \lim(\hat{\beta}) = \beta \dots\dots\dots (5.34)$$

ومنه نقول بوجود الفرضيتين (32.5)، (33.5) يكون  $\hat{\beta}$  مقدرًا متسقًا. أما

لما يزداد حجم العينة، فتوزيع المقدر  $\hat{\beta}$  يكون بناءً أعلى للنتيجتين:

$$P \lim(n^{-1}X'X) = Q$$

$$n^{-1/2}(X'U) \xrightarrow{D} \eta \sim N(0, \sigma_u^2 Q)$$

على الشكل:

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{D} Q^{-1}\eta \sim N(0, \sigma_u^2 Q^{-1}) \dots\dots\dots (5.35)$$

### 3-5 التوزيعات التقاربية لمقدر المعقولية العظمى:

#### 1-3-5 طريقة المعقولية العظمى:

تستعمل طريقة المربعات الصغرى والتقنيات المرتبطة بها العزم الأول والثاني (الوسط والتباين على التوالي) للملاحظات فقط. ففي بناء أي نموذج يكون شكل التوزيع مخصصا مسبقا، والتقيد بالعزمين الأوليين يمكن. أن يكون إحصائيا غير كاف، وتحاول طريقة المعقولية العظمى إدخال كل المعلومات في النموذج بواسطة الإهتمام بالتوزيع الكامل للملاحظات. حيث في النموذج الخطي العام تقترح نظرية "قوس-ماركوف" مبررات استعمال طريقة المربعات الصغرى. وتكون الفرضية الوحيدة الموضوعية حول توزيع الملاحظات هي وجود العزمين الأولين (الوسط والتباين) ومنه تكون مقدرات المربعات الصغرى أفضل مقدرات مثلما لاحظنا من قبل. لكن لا يمكننا تطبيق نفس المعايير على النموذج الديناميكي (والذي سوف نتطرق إليه في الفصل السابع)، وذلك بالرغم من بقاء الهدف نفسه في التقدير وهو تصغير مجموع مربعات البواقي.

ولنفرض أنه لدينا عينة تحتوي على مجموعة من  $n$  ملاحظات لمتغيرات عشوائية  $Y_1, Y_2, \dots, Y_n$ . ويخصص النموذج الإحصائي توزيعات لـ  $Y_1, Y_2, \dots, Y_n$  تعرف باسم دالة الكثافة المشتركة. تعتمد هذه الأخيرة على  $k$  معلمة غير معروفة في شكل موجه  $\theta = (\theta_1, \dots, \theta_k)$ . ونمثل دالة الكثافة المشتركة بواسطة دالة المعقولية  $L(y_1, \dots, y_n, \theta)$ ، ونشرحها على أنها احتمال الحصول على القيم الخاصة بـ  $Y_1, Y_2, \dots, Y_n$ . وبمجرد سحب العينة من المجتمع، تصبح الملاحظات  $Y_1, Y_2, \dots, Y_n$  عبارة عن مجموعة أعداد مثبتة، ويعبر بعد ذلك عن دالة الكثافة المشتركة بأنها دالة لموجه المعالم  $\theta$ ، حيث أن  $\theta$  هي أية قيمة مقبولة لموجه المعالم، عوضا عن القيمة الحقيقية. ومنه نسمي هذه الدالة بدالة المعقولية ونرمز لها بالرمز  $L(\theta)$ . وتكون طريقة المعقولية



العظمى هي تقدير الموجه  $\theta$  بمعرفة ملاحظات العينة. ويعطى هذا المقدّر بالرمز  $\tilde{\theta}$  بحيث يحقق هذا المقدّر الشرط:

$$L(\tilde{\theta}) \geq L(\bar{\theta}) \dots (5.36)$$

حيث أن  $\bar{\theta}$  هي أي مقدّر آخر بطريقة بديلة.

ومنه يكون قانون مقدّر المعقولية العظمى هو ذلك المقدّر الذي يضمن ويحقق الشرط المذكور في المعادلة (36.5). وتعتمد نظرية التقدير بالمعقولية العظمى على فكرة سحب الملاحظات  $n$  من نفس التوزيع بطريقة مستقلة. ومنه تكون دالة الكثافة المشتركة لكل الملاحظات (دالة المعقولية العظمى) على الشكل:

$$L(y_1, \dots, y_n, \theta) = \prod_{i=1}^n \Pr(y_i, \theta) \dots (5.37)$$

حيث أن:  $\Pr(y_i, \theta)$  هي دالة الكثافة الإحتمالية لـ  $y_i$  ( $i = 1, 2, \dots, n$ ). تعتبر  $L(\theta)$  دالة مستمرة لـ  $\theta$  ويمكن أن نحصل على مقدّر المعقولية العظمى عن طريق الاشتقاق بالنسبة لموجه المعالم غير المعروفة، ويكون من الأسهل إدخال اللوغاريتم الطبيعي على هذه الدالة (37.5) مادام هذا الإجراء لا يؤثر على الشرط الموجود بالمعادلة (36.5). إن المشتقات الجزئية الأولى للموجه  $\theta \leftarrow 1 \times k$  من الشكل  $\partial \log L(\theta) / \partial \theta$  تكون على النحو:

$$\frac{\partial \log L(\theta)}{\partial \theta} = \begin{bmatrix} \frac{\partial \log L(\theta)}{\partial \theta_1} \\ \vdots \\ \frac{\partial \log L(\theta)}{\partial \theta_k} \end{bmatrix} = \underset{\sim}{0} \dots (5.38)$$

وللتبسيط نعيد كتابة المعادلة (38.5) على الشكل:

$$D \log L(\theta) = 0 \dots (5.39)$$

و يمكن أن يقيم المشتق الأول بالمعادلة (39.5) عند أية نقطة. فكتابة  $D \log L(\tilde{\theta})$  يشير إلى موجه المشتقات الأولى مقيم عند النقطة  $\theta = \tilde{\theta}$ . أي:



$$D \log L(\tilde{\theta}) = \left. \frac{\partial \log L(\theta)}{\partial \theta} \right|_{\theta=\tilde{\theta}} \dots\dots (5.40)$$

وبنفس الطريقة يمكن للمصفوفة  $k \times k$  من المشتقات الثانية أن تكون:

$$D^2 \log L(\tilde{\theta}) = \left. \frac{\partial^2 \log L(\theta)}{\partial \theta \partial \theta'} \right|_{\theta=\tilde{\theta}} \dots\dots (5.41)$$

حيث تشير المعادلة (41.5) إلى المصفوفة الهيسية Hessian Matrix للوغاريتم دالة المعقولية العظمى عند المقدّر  $\tilde{\theta}$ .

ويكون مقدّر المعقولية العظمى  $\tilde{\theta}$  حلا لمعادلات المعقولية العظمى المذكورة بالمعادلة (39.5). ومادام أن هناك أكثر من حل للمعادلة (39.5)، فمن المهم التأكد من أننا وصلنا إلى أعظم نقطة. ونصل إلى أعظم نقطة لدالة المعقولية لما تكون المصفوفة الهيسية في (41.5) سالبة شبه محددة. وسنوضح ذلك لدى تطرقنا لنظرية Cramer-Rao فيما بعد.

### 2-3-5 الشروط النظامية:

ننظر الآن إلى تقدير المعقولية بصفة عامة. ولنفرض أنه لدينا عينة عشوائية بملاحظات المتغيرات التابعة  $y_i, n \times 1$  و  $X$  مصفوفة ملاحظات متغيرات مستقلة  $n \times k$  و  $\theta$  هي  $k \times 1$  موجه لمعالم نموذج ما. ولتكن دالة كثافتها المشتركة  $\Pr(y, \theta, X)$  وذات التوزيع المستمر على الشكل:

$$\begin{aligned} \Pr(y, \theta, X) &= f(y_1, \theta, X_1) \cdot f(y_2, \theta, X_2) \cdot \dots \cdot f(y_n, \theta, X_n) \\ &= L(\theta, y, X) = L(\theta) = L \dots\dots\dots (5.42) \end{aligned}$$

حيث  $L(\theta)$  هي دالة المعقولية من أجل أي  $\theta$ . ويفترض في دالة المعقولية العظمى بالمعادلة (42.5) أن يكون لها المشتقات الجزئية الأولى والثانية بالنسبة لـ  $\theta$ . وتكون هذه المشتقات مستمرة بالنسبة لـ  $y$ . ومنه تسمح المشتقات  $\log L(\theta)$  بأن تكون مستمرة وكمتغيرات عشوائية.

إن تعظيم دالة المعقولية يعطي:

$$\partial \log L(\theta) / \partial \theta = \left( \frac{1}{L} \right) \frac{\partial L(\theta)}{\partial \theta} = 0 \dots \dots (5.43)$$

وإذا أعطتنا هذه المشتقة معادلات غير خطية في  $\theta$ ، تكون طريقة التكرار (6) ضرورية للحصول على مقدار المعقولية العظمى  $\tilde{\theta}$ ، وللتبسيط نستعين بالتعريف الموجود بالمعادلة (39.5). ونعيد كتابة (43.5):

$$D \log L(\theta) = \left( \frac{1}{L} \right) \frac{\partial L(\theta)}{\partial \theta} \dots \dots (5.44)$$

وإذا كانت  $\tilde{\theta}$  هي مقدار المعقولية العظمى، يجب أن تحقق الشروط الأولى للاشتقاق، وهي:

$$D \log L(\tilde{\theta}) = 0 \dots \dots (5.45)$$

وبما أن دالة المعقولية العظمى  $L(\theta)$  هي نفسها دالة الكثافة  $f(\theta, y)$  الأولى مفسرة بدلالة المعالم  $\theta$ ، والثانية مفسرة بدلالة المعالم  $\theta$  والملاحظات  $y_i$ ، كما أن تكامل دوال الكثافة يساوي الواحد. فإنه يكون تكامل  $L(\theta)$  بالنسبة لفضاء العينة مساو للواحد من أجل أية قيمة مقبولة لـ  $\theta$ . أي أن دالة الكثافة ذات  $n$  أبعاد تستلزم أن:

$$\int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} L(y_1, \dots, y_n, \theta) dy_1 \dots dy_n = 1$$

حيث أن نهاية التكامل أعلاه مستقلة عن  $\theta$  والتفاضل تحت التكامل يكون مقبولا. وهي ما تسمى بالشروط النظامية. ومنه يمكن إعادة كتابة العبارة أعلاه في شكل موجّهات على النحو:

$$\int_{-\infty}^{+\infty} L(\theta) dy = 1 \dots \dots (5.46)$$

6- أنظر:

A.C. HARVEY 1981, Page 87. "The Econometric Analysis of Time Series"  
Philip Alan OXFORD



وباشتقاق طرفي المعادلة (46.5) بالنسبة لـ  $\theta$  وباستعمال النتيجة (43.5) نجد:

$$\frac{\partial}{\partial \theta} \int_{-\infty}^{+\infty} L(\theta) dy = \int_{-\infty}^{+\infty} \frac{\partial L(\theta)}{\partial \theta} dy = \int_{-\infty}^{+\infty} \frac{\partial \log L(\theta)}{\partial \theta} L(\theta) dy = 0 \dots (5.47)$$

وباستعمال المعادلة (39.5) تصبح المعادلة (47.5) أعلاه على الشكل:

$$\int_{-\infty}^{+\infty} D \log L(\theta) \cdot L(\theta) dy = 0 \dots (5.48)$$

و ما دامت دالة المعقولية  $L(\theta)$  متماثلة (متكافئة) مع دالة الكثافة المشتركة  $Pr(y, \theta, X)$  والتي هي عشوائية، فإن مشتقها هو كذلك عشوائي بالنسبة لـ  $\theta$  وتكون نتيجة المعادلة (48.5) متناسقة مع توقع مشتقة اللوغاريتم لدالة المعقولية. ونعيد كتابة المعادلة (48.5) على الشكل:

$$E[D \log L(\theta)] = \int D \log L(\theta) \cdot L(\theta) dy = 0 \dots (5.49)$$

حيث أن التكامل هو لفضاء العينة.

إن اشتقاق المعادلة (47.5) (وبالتالي (48.5)) مرة ثانية بالنسبة لـ  $\theta'$ ، يمكن أن يعطينا عبارة لتباين  $D \log L(\theta)$ . وللتأكد من أن الأبعاد محترمة تذكر أن  $\partial^2() / \partial \theta \partial \theta'$  تكافئ  $\partial^2() / \partial \theta'^2$  المطبقة على موجه الأعمدة للمشتقات الجزئية الأولى في (47.5). إذن بإشتقاق هذه الأخيرة بالنسبة لـ  $\theta'$  نجد:

$$\begin{aligned} \frac{\partial}{\partial \theta'} \int \frac{\partial \log L(\theta)}{\partial \theta} \cdot L(\theta) dy &= 0 \\ &= \int \left[ \frac{\partial^2 \log L(\theta)}{\partial \theta \partial \theta'} \cdot L(\theta) + \frac{\partial \log L(\theta)}{\partial \theta} \cdot \frac{\partial L(\theta)}{\partial \theta'} \right] dy = 0 \\ &= \int \frac{\partial^2 \log L(\theta)}{\partial \theta \partial \theta'} \cdot L(\theta) dy + \int \frac{\partial \log L(\theta)}{\partial \theta} \cdot \frac{\partial \log L(\theta)}{\partial \theta'} \cdot L(\theta) dy = 0 \dots (5.50) \end{aligned}$$

وباستعمال المعادلة (39.5) ومايناسبها بالمعادلة (41.5) تصبح نتيجة المعادلة (50.5) على الشكل:

$$\int D^2 \log L(\theta) \cdot L(\theta) dy + \int D \log L(\theta) \cdot D \log L'(\theta) dy = 0 \dots (5.51)$$



إن الحد الأول ليسار المعادلة (51.5) هو توقع لوغاريتم المشتقة الثانية وهي  $(k \times k)$  مصفوفة. ونكتبها على الشكل:

$$E[D^2 \log L(\theta)] = \int D^2 \log L(\theta) \cdot L(\theta) \cdot dy \dots (5.52)$$

أما الحد الثاني ليسار نفس المعادلة فهو التباين المشترك للمشتقة الأولى  $D \log L(\theta)$  أي:

$$\begin{aligned} \text{var}[D \log L(\theta)] &= E[(D \log L(\theta))(D \log L(\theta)')] \\ &= \int \frac{\partial \log L(\theta)}{\partial \theta} \cdot \frac{\partial \log L(\theta)}{\partial \theta'} \cdot L(\theta) \cdot dy \dots (5.53) \end{aligned}$$

و ما دام  $E[D \log L(\theta)] = 0$  من المعادلة (49.5) فإن صيغة المعادلة (53.5) تكافئ مصفوفة التباين -التباين المشترك للموجه العشوائي  $D \log L(\theta)$  ومنه نعيد كتابة المعادلة (51.5) على الشكل:

$$E[D^2 \log L(\theta)] + \text{var}[D \log L(\theta)] = 0 \dots (5.54)$$

لينتج لدينا:

$$\text{var}[D \log L(\theta)] = -E[D^2 \log L(\theta)] \dots (5.55)$$

وتسمى المصفوفة  $k \times k$  على يمين المعادلة (55.5) بمصفوفة المعلومات Information Matrix ونكتب على الشكل:

$$I(\theta) = -E[D^2 \log L(\theta)] \dots (5.56)$$

ومنه نقول أنه من أجل  $\theta$  والتي تحقق:

(i)  $\Pr(y, \theta, X)$  كدالة كثافة مشتركة.

(ii)  $D \log L(\theta)$  موجه عشوائي.

(iii) تتوزع  $D \log L(\theta)$  بوسط مساو للصفر، وتباين مساو لمصفوفة المعلومات

$$D \log L(\theta) \sim [0, I(\theta)] \quad \text{أي:}$$

فإنه توجد قيمة صحيحة ووحيدة لـ  $\theta$  والتي تحقق الشرطين:

$$a) E[D \log L(\theta)] = 0$$

$$b) \text{var}[D \log L(\theta)] = I(\theta) = -E[D^2 \log L(\theta)]$$

### 3-3-5 اشتقاق متراجحة Cramer-Rao

ليكن لدينا المقدّر غير المتحيّز  $\hat{\theta}$  لـ  $\theta$ ، ومنه بالتعريف يصبح لدينا:

$$E(\hat{\theta}) = \theta$$

$$E(\hat{\theta}) = \int \hat{\theta} L(\theta) dy = \theta \dots (5.57)$$

وباشتقاق (57.5) بالنسبة لـ  $\theta$  نجد:

$$\int \hat{\theta} D \log L(\theta) \cdot L(\theta) \cdot dy = 1 \dots (5.58)$$

ولدينا المعادلة (49.5)،  $E[D \log L(\theta)] = 0$ ، وبالتالي يمكن كتابة العبارة:

$$E[\theta \cdot D \log L(\theta)] = \theta \cdot E[D \log L(\theta)] = 0$$

وبإدخال هذه العبارة بالمعادلة (58.5) نعطى:

$$1 = \int (\hat{\theta} - \theta) D \log L(\theta) \cdot L(\theta) \cdot dy$$

ومنّه بإستعمال متراجحة Cauchy-Schwartz، نجد:

$$\left[ \int_{-\infty}^{+\infty} (\hat{\theta} - \theta)^2 \cdot L(\theta) \cdot dy \right] \left[ \int_{-\infty}^{+\infty} (D \log L(\theta))^2 \cdot L(\theta) \cdot dy \right] \geq 1$$

ومنّه لما يكون  $\hat{\theta}$  موجه  $k \times 1$  تصبح:

$$\left[ \int (\hat{\theta} - \theta)(\hat{\theta} - \theta)' \cdot L(\theta) \cdot dy \right] \left[ \int D \log L(\theta) \cdot D \log L(\theta)' \cdot L(\theta) \cdot dy \right] \geq 1 \dots (5.59)$$

إن الحد الأول للمعادلة (59.5) هو  $\text{var}(\hat{\theta})$ . أما الحد الثاني فهو مصفوفة

المعلومات المعرفة بالمعادلة (55.5). ومنّه نعيد كتابة المعادلة (59.5) على الشكل:

$$[\text{var}(\hat{\theta})][I(\theta)] \geq I$$

ومنّه نجد:

$$\text{var}(\hat{\theta}) \geq I^{-1}(\theta) \dots (5.60)$$

وهو ما يسمى بمتراجحة Cramer-Rao.



### مثال: (1.5):

لنأخذ لوغاريتم دالة المعقولية في عينة ملاحظات  $n$  لمتغيرات عشوائية مستقلة  $y$  من التوزيع الطبيعي بوسط  $\mu$  وتباين  $\sigma^2$ ، على الشكل:

$$\log L(\mu, \sigma^2) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \cdot \sum_{i=1}^n (y_i - \mu)^2$$

حيث هنا  $\theta = (\mu, \sigma^2)'$  وتكون عناصر  $D \log L(\theta)$  هي:

$$\frac{\partial \log L}{\partial \mu} = \frac{1}{\sigma^2} \cdot \sum (y_i - \mu) = 0$$

$$\frac{\partial \log L}{\partial \sigma^2} = \frac{-n^2}{2\sigma^2} + \frac{1}{2\sigma^4} \cdot \sum (y_i - \mu)^2 = 0$$

ومنه نجد:

$$\left. \begin{aligned} \tilde{\mu} &= \frac{\sum y_i}{n} = \bar{y} \\ \tilde{\sigma}^2 &= \frac{\sum (y_i - \mu)^2}{n} \end{aligned} \right\} \dots\dots (5.61)$$

إن العبارتين بالمعادلة (61.5) تعتبران الحلين الوحيدين لمعادلتين المعقولية. ومراجعة بسيطة لمصفوفة المشتقات الجزئية الثانية (المصفوفة الهيسية) تبين بأن هاتين القيمتين  $(\tilde{\mu}, \tilde{\sigma}^2)$  فعلا تعظمان  $\log L(\theta)$ ، أي:

$$D^2 \log L(\theta) = \begin{bmatrix} \frac{\partial^2 \log L}{\partial \mu^2} & \frac{\partial^2 \log L}{\partial \mu \partial \sigma^2} \\ \frac{\partial^2 \log L}{\partial \sigma^2 \partial \mu} & \frac{\partial^2 \log L}{\partial (\sigma^2)^2} \end{bmatrix}$$



$$= \begin{bmatrix} \frac{-n}{\sigma^2} & -\frac{1}{\sigma^4} \cdot \sum (y_i - \mu) \\ -\frac{1}{\sigma^4} \cdot \sum (y_i - \mu) & \frac{n}{2\sigma^4} - \frac{1}{\sigma^2} \sum (y_i - \mu)^2 \end{bmatrix}$$

وبالتعويض في المعادلة (61.5) نجد:

$$D^2 \log L(\theta) = - \begin{bmatrix} \frac{n}{\tilde{\sigma}^2} & 0 \\ 0 & \frac{n}{2\tilde{\sigma}^4} \end{bmatrix} \leq 0 \dots (5.62)$$

و مادام  $\tilde{\sigma}^2 > 0$  فمن الواضح أن العبارة (62.5) سالبة شبه محددة، ومنه تكون:

$$I(\mu, \sigma^2) = \begin{bmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{bmatrix} = -E[D^2 \log L(\theta)] \geq 0 \dots (5.63)$$

وتقترح علينا متراجحة Cramer-Rao أن تكون مصفوفة التباين المشترك لموجه المقدرات  $\hat{\theta}$  تفوق معكوس مصفوفة المعلومات كما هو مبين في المعادلة (60.5) بمصفوفة موجبة شبه محددة. ومنه يكون:

$$I^{-1}(\theta) = \begin{bmatrix} \sigma^2/n & 0 \\ 0 & 2\sigma^4/n \end{bmatrix} \dots (5.64)$$

أصغر تباين محدود (M.V.B) Minimum Variance Bounded، نقول عن المقدر  $\tilde{\theta}$  بأنه مقدر كفو، وإذا كان  $\tilde{\theta}$  مقدرًا غير متحيز في هذه الحالة نقول عن هذا المقدر ( $\tilde{\theta}$ ) بأنه مقدر غير متحيز بأصغر تباين Minimum Variance Unbiased (M.V.U.E) Estimator.

## مثال (2.5):

لنعتبر النموذج الخطي العام  $Y = X\beta + U$  مع  $X$  غير عشوائية وموجه الأخطاء يخضع لقانون التوزيع الطبيعي  $U \sim N(0, \sigma_u^2)$ . تكون دالة الكثافة لملاحظات المتغير التابع:

$$P(y, \beta, \sigma^2) = (2\pi\sigma_u^2)^{-n/2} \cdot \exp\left[-(y - X\beta)'(y - X\beta)/2\sigma_u^2\right]$$

تفسر دالة الكثافة على أنها دالة لـ  $y$  بمعرفة المعالم  $\beta$ ،  $\sigma^2$ . وتكون دالة المعقولة العظمى لها نفس الشكل، لكنها مفسرة بدلالة المعالم. ومنه نكتب دالة المعقولة العظمى كمايلي:

$$L(\beta, \sigma_u^2, y) = (2\pi\sigma_u^2)^{-n/2} \cdot \exp\left[-\frac{1}{2\sigma_u^2} \cdot U'U\right]$$

و بإدخال اللوغاريتم الطبيعي نجد:

$$\log L = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma_u^2 - \frac{1}{2\sigma_u^2} (y - X\beta)'(y - X\beta) \dots (5.65)$$

إن تعظيم (65.5) بالنسبة للمعالم  $\beta$ ،  $\sigma_u^2$  يعطي:

$$\frac{\partial \log L}{\partial \tilde{\beta}} = \frac{1}{\tilde{\sigma}_u^2} (X'y - X'X\tilde{\beta}) = 0$$

$$\frac{\partial \log L}{\partial \tilde{\sigma}_u^2} = -\frac{n}{2\tilde{\sigma}_u^2} + \frac{1}{2\tilde{\sigma}_u^2} (y - X\tilde{\beta})'(y - X\tilde{\beta}) = 0$$

ومنه ينتج:

$$\left. \begin{aligned} \tilde{\beta} &= (X'X)^{-1} X'y = \hat{\beta} \\ \tilde{\sigma}_u^2 &= \frac{(y - X\hat{\beta})'(y - X\hat{\beta})}{n} = \frac{\hat{U}'\hat{U}}{n} \end{aligned} \right\} \dots (5.66)$$

و منه نلاحظ أن مقدار المعقولية العظمى  $\tilde{\sigma}_u^2$  يختلف عن مقدار المربعات الصغرى العادية  $\hat{\sigma}_u^2$  حيث أن الأول متحيز والثاني غير متحيز. لكن تقريبا يضمن هذا التحيز مثلما سنرى فيما بعد.

أما المشتقات الجزئية الثانية فهي:

$$\frac{\partial^2 \log L}{\partial \tilde{\beta} \partial \tilde{\beta}'} = -\frac{1}{\tilde{\sigma}_u^2} X'X$$

$$\frac{\partial^2 \log L}{\partial (\tilde{\sigma}_u^2)^2} = \frac{n}{2\tilde{\sigma}_u^4} - \frac{RSS}{\tilde{\sigma}_u^6}$$

$$\frac{\partial^2 \log L}{\partial \tilde{\beta} \partial \tilde{\sigma}_u^2} = -\frac{1}{2\tilde{\sigma}_u^4} (X'y - X'X\tilde{\beta})$$

وبأخذ توقعات القيم أعلاه وتحويل الإشارة نجد:

$$-E\left[\frac{\partial^2 \log L}{\partial \tilde{\beta} \partial \tilde{\beta}'}\right] = \frac{1}{\sigma_u^2} X'X$$

$$-E\left[\frac{\partial^2 \log L}{\partial (\tilde{\sigma}_u^2)^2}\right] = \frac{n}{2\sigma_u^4}$$

$$E(RSS) = n\sigma_u^2 \quad \text{لأن}$$

$$-E\left[\frac{\partial^2 \log L}{\partial \tilde{\beta} \partial \tilde{\sigma}_u^2}\right] = 0$$

$$E[X'y - X'X\tilde{\beta}] = E[X'y - X'X\hat{\beta}] \quad \text{لأن:}$$

$$= E[X'(y - X\hat{\beta})] = E(X'\hat{U}) = 0$$

وباستعمال المعادلة (56.5) لدينا:

$$I(\theta) = I\left(\begin{matrix} \beta \\ \sigma_u^2 \end{matrix}\right) = -E[D^2 \log L(\beta, \sigma_u^2)]$$



أي أن:

$$I \begin{pmatrix} \beta \\ \sigma_u^2 \end{pmatrix} = -E \begin{bmatrix} \frac{\partial^2 \log L}{\partial \tilde{\beta} \partial \tilde{\beta}'} & \frac{\partial^2 \log L}{\partial \tilde{\beta} \partial \tilde{\sigma}_u^2} \\ \frac{\partial^2 \log L}{\partial \tilde{\sigma}_u^2 \partial \tilde{\beta}} & \frac{\partial^2 \log L}{\partial (\tilde{\sigma}_u^2)^2} \end{bmatrix}$$

$$I \begin{pmatrix} \beta \\ \sigma_u^2 \end{pmatrix} = \begin{bmatrix} \frac{1}{\sigma_u^2} X'X & 0 \\ 0 & \frac{n}{2\sigma_u^4} \end{bmatrix}$$

لتصبح:

$$I^{-1} \begin{pmatrix} \beta \\ \sigma_u^2 \end{pmatrix} = \begin{bmatrix} \sigma_u^2 (X'X)^{-1} & 0 \\ 0 & \frac{2\sigma_u^4}{n} \end{bmatrix} \geq 0 \dots (5.67)$$

و هذا ما يتطابق مع متراجحة Cramer-Rao حيث أن مقدرات المعقولية العظمى تحقق شروط Cramer-Rao والمتمثلة في (M.V.B).

#### 4-3-5 الخصائص التقاربية لمقدر المعقولية العظمى:

يعتمد مقدر المعقولية العظمى على معلومات العينة فقط. ومنه لما يوجد مقدر غير متحيز وبتباين ذو أصغر حد نقول عن هذا الأخير بأنه متماثل (متكافئ) مع مقدر المعقولية العظمى. وبالرغم من صعوبة الحصول على مقدر له خاصية أصغر حد للتباين، مثلما شاهدنا في المثال (1.5) والمتعلق بتقدير  $\sigma_u^2$  (حيث أن  $\tilde{\sigma}_u^2$  في هذه الحالة هو متحيز)، فإنه يمكننا القول بأن هذا التحيز يصبح عديم المفعول لما يزداد حجم العينة  $n$  بشكل كبير. حيث من المعادلة (61.5) لدينا:

$$\tilde{\sigma}^2 = \frac{\sum (y_i - \tilde{\mu})^2}{n} = \frac{\sum (y_i - \bar{y})^2}{n}$$

$$E(\tilde{\sigma}^2) = \frac{E(RSS)}{n} = \frac{(n-1)\sigma^2}{n}$$

ومنه لما  $n \rightarrow \infty$  فإن:  $E(\tilde{\sigma}^2) = \sigma^2$

كما أن تباين  $\tilde{\sigma}^2$  يتجه عند أدنى حد للتباين وهو  $2\sigma^4/n$  وهو ما يبين بأن مقدرات المعقولة العظمى عادة، تحقق الحد الأدنى لـ Cramer-Rao في العينات الكبيرة.

وبينا من قبل بأن:  $D \log L(\theta) \sim [0, I(\theta)]$  لنستنتج أن:

$$\left. \begin{aligned} n^{-1/2} D \log L(\theta) &\sim [0, n^{-1} I(\theta)] \\ n^{-1} D \log L(\theta) &\sim [0, n^{-2} I(\theta)] \end{aligned} \right\} \dots (5.68)$$

و إذا فرضنا أنه كلما  $n \rightarrow \infty$ ، فإن  $n^{-1} I(\theta)$  تتقارب إلى نهاية معروفة وتساوي المصفوفة المحددة الموجبة  $Q$ ، فإنه يمكن الإقتراح بأن المقدر  $n^{-1/2} D \log L(\theta)$  يتقارب بالتوزيع إلى متغير عشوائي، وليكن  $\eta$ ، كمايلي:

$$n^{-1/2} D \log L(\theta) \xrightarrow{D} \eta \sim N(0, Q) \dots (5.69)$$

كما أن  $n^{-1} D \log L(\theta)$  ذات الوسط صفر والتباين  $(n^{-2} I(\theta))$ ، تتقارب إلى الصفر لما  $n \rightarrow \infty$  ومنه باستعمال قاعدة CHEBYSHEV تكون هذه الأخيرة متقاربة بالإحتمال إلى الصفر، أي:

$$n^{-1} D \log L(\theta) \xrightarrow{P} 0 \dots (5.70)$$

ونستعين الآن بهاتين النتيجةين (بالمعادلتين (69.5)، (70.5)) لمناقشة خصائص مقدر المعقولة العظمى بالنسبة لـ  $\tilde{\theta}$ .

في عينة لـ  $n$  ملاحظات مستقلة ومسحوبة عن دالة كثافة احتمالية تحتوي على موجه المعالم  $\theta$ ، تكون معادلات المعقولة والتي تحقق شروط الإشتقاق الأولى من النوع  $D \log L(\tilde{\theta}) = 0$ . وهناك عدة حلول ممكنة للمعادلة (45.5)،



لكن النقطة الوحيدة التي تحقق الشروط النظامية هي تلك القيمة  $\tilde{\theta}$ . وإذا تحقق ذلك فإنه لإشتقاق الخصائص التقاربية لمقدر المعقولة العظمى، نقوم بتطبيق نظرية تايلور لتوسيع السلاسل حول القيمة الحقيقية لـ  $\theta$  لنجد:

$$D \log L(\tilde{\theta}) = 0$$

$$\approx D \log L(\theta) + D^2 \log L(\theta) \cdot (\tilde{\theta} - \theta) + (\tilde{\theta} - \theta)' \cdot D^2 \log L(\theta) \cdot (\tilde{\theta} - \theta) + \dots$$

لكن بتوفر الشروط النظامية يكون الحد الثالث على يمين المعادلة أعلاه صغيرا جدا ومنه نعيد كتابتها على الشكل:

$$D \log L(\tilde{\theta}) \approx D \log L(\theta) + D^2 \log L(\theta) \cdot (\tilde{\theta} - \theta) + R_1 = 0 \dots (5.71)$$

حيث تمثل  $R_1$  القيمة الباقية وتكون العبارة  $D^2 \log L(\theta)$  غير شاذة. ومنه يمكن إعادة كتابة (5.71) على الشكل:

$$(\tilde{\theta} - \theta) \approx -[D^2 \log L(\theta)]^{-1} \cdot D \log L(\theta) \dots (5.72)$$

ومن المعادلة (5.56)، لدينا:

$$I(\theta) = E[-D^2 \log L(\theta)]$$

لنجد أن:

$$E[-n^{-1} D^2 \log L(\theta)] = n^{-1} I(\theta)$$

$$\lim_{n \rightarrow \infty} [n^{-1} I(\theta)] \rightarrow Q \quad \text{كما أن:}$$

وبالرغم من أن العبارة أعلاه غير كافية لكي نثبت بأن  $-n^{-1} D^2 \log L(\theta)$  تتقارب بالاحتمال إلى  $Q$ ، فإننا نقول إذا كانت هذه النهاية  $Q$  موجودة، فمن الممكن جدا أن تساوي توقع المقدار أعلاه. ومنه نقول أنه تحت شروط معينة تكون:

$$\text{plim}[-n^{-1} D^2 \log L(\theta)] = \lim_{n \rightarrow \infty} [n^{-1} I(\theta)] = Q \dots (5.73)$$



ومنه نقول إذا كانت عبارة المعادلة (73.5) صحيحة (محقة) فإنه من المعادلة (72.5) نجد:

$$\begin{aligned}(\tilde{\theta} - \theta) &\approx -[D^2 \log L(\theta)]^{-1} \cdot D \log L(\theta) \\&= [-n^{-1} D^2 \log L(\theta)]^{-1} [n^{-1} D \log L(\theta)] \\&\rightarrow Q^{-1} \cdot 0 = 0\end{aligned}$$

وهذا شريطة أن تكون الحدود الباقية  $R_1$  متقاربة بالإحتمال إلى الصفر، لنجد أن:

$$p \lim(\tilde{\theta} - \theta) = 0 \Rightarrow p \lim(\tilde{\theta}) = \theta$$

ومنه نقول بأن مقدر المعقولية العظمى  $\tilde{\theta}$  هو مقدر متسق لـ  $\theta$ . لتصبح لدينا:

$$\sqrt{n}(\tilde{\theta} - \theta) \approx [-n^{-1} D^2 \log L(\theta)]^{-1} [n^{-1/2} D \log L(\theta)]$$

وإذا كانت:

$$a) n^{-1/2} D \log L(\theta) \xrightarrow{D} \eta \sim N(0, Q)$$

$$b) -n^{-1} D^2 \log L(\theta) \xrightarrow{P} Q$$

ثم بإستعمال المعادلة (18.5) (نظرية Cramer) نجد:

$$\begin{aligned}\sqrt{n}(\tilde{\theta} - \theta) &\xrightarrow{D} Q^{-1} \eta \sim N(0, Q^{-1} Q Q^{-1}) \\ \sqrt{n}(\tilde{\theta} - \theta) &\xrightarrow{D} Q^{-1} \eta \sim N(0, Q^{-1})\end{aligned}$$

أو:

ومنه نقول أنه بالنسبة للعينات الكبيرة والنهائية نكتب:

$$\tilde{\theta} \overset{A}{\sim} N(\theta, n^{-1} Q^{-1}) \dots \dots (5.74)$$

ولإستعمال المعادلة (74.5) عمليا، من الضروري تعويض  $n^{-1} Q^{-1}$  بتقريب لعينة نهائية مناسبة وذلك وفقا للخطوات التالية:

$$\bullet n^{-1} I(\theta) \text{ هي تقريب لـ } Q.$$

$$\bullet n[I(\theta)]^{-1} \text{ هي تقريب لـ } Q^{-1}.$$

$[I(\theta)]^{-1}$  هي تقريب لـ  $n^{-1}Q^{-1}$ .

ونظرا لعدم معرفتنا لقيمة  $\theta$ ، فإننا نقول بأن  $n[I(\tilde{\theta})]^{-1}$  هي مقدر متسق لـ  $Q^{-1}$  ومنه يمكن استعمال  $[I(\tilde{\theta})]^{-1}$  لتعويض عن  $n^{-1}Q^{-1}$  المعادلة (74.5)، ومنه نعيد كتابة (74.5) على الشكل:

$$\tilde{\theta} \overset{A}{\sim} N[\theta, I^{-1}(\tilde{\theta})] \dots (5.75)$$

ولمناقشة الكفاءة التقاربية لمقدر المعقولية العظمى  $\tilde{\theta}$ ، نقول بأن:

$$\sqrt{n}(\tilde{\theta} - \theta) \sim N[0, Q^{-1}]$$

والذي له نهاية مساوية لـ  $Q^{-1}$ ، ثم نعتبر  $\hat{\theta}$  مقدر ما للموجه  $\theta$  ويحقق:

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{D} B \sim N(0, \Sigma^{-1})$$

نقول عن  $\tilde{\theta}$  بأنه مقدر المعقولية العظمى الكفو تقاربيا إذا تحقق:

$$\Sigma^{-1} - Q^{-1} = Z$$

حيث  $Z$  مصفوفة موجبة شبه محددة، وبعبارة أخرى نقول بأن مقدر المعقولية العظمى الذي يحقق الحد الأدنى لـ Cramer Rao يكون تباينه أصغر من أو يساوي تباين أي مقدر آخر غير متحيز تقاربيا.

### 5-3-5 مقدر المعقولية العظمى المقيد:

إن نتائج الاستنباط الإحصائي لنموذج الإنحدار الخطي والمشتقة بالفصل الثالث تعتمد على الفرضية القائلة بأنه لا توجد معلومات متوفرة مسبقا حول  $\theta = (\beta, \sigma_u^2)$ . ولكن نظرا لإهتمامنا بالنموذج الخطي العام تطرقنا إلى القيود الخطية فقط. ويمكن أن تكون لدينا معلومات إضافية أخرى مثل القيود غير الخطية، القيود الصحيحة، القيود غير الصحيحة والقيود العشوائية. وسوف نتطرق في هذه الفقرة، للقيود الصحيحة فقط للمعلومات المسبقة حول الموجه  $\beta$ ، أما المعلومات المسبقة حول  $\sigma_u^2$  فهي صعبة الحصول.

(a) القيود الخطية المسبقة على الموجه  $\beta$ :

لنفرض أنه لدينا معلومة مسبقة ذات  $m$  قيود خطية من الشكل:

$$R\beta = r$$

مع النموذج الخطي العام:

$$y = X\beta + U$$

وعند تقديرنا لموجه المعالم  $\theta = (\beta, \lambda, \sigma_u^2)$ ، يمكن أخذ هذه القيود بعين الاعتبار عن طريق توسيع مفهوم دالة لوغاريتم دالة المعقولية  $\log L$  لتحتوي على هذه القيود. ونحقق ذلك بتعريف الدالة اللاقرانجية التالية:

$$Q(\theta, \lambda, y, X) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma_u^2 - \frac{1}{2\sigma_u^2} (y - X\beta)'(y - X\beta) - \lambda'(R\beta - r) \dots (5.76)$$

حيث أن  $\lambda$  هي  $m \times 1$  موجه لمضاعفات لاغرانج. إن تعظيم (76.5) بالنسبة لـ  $\beta, \sigma_u^2, \lambda$ ، يعطي النتائج:

$$\frac{\partial Q}{\partial \beta} = \frac{1}{\sigma_u^2} (X'y - X'X\beta) - R'\lambda = 0 \dots (1)$$

$$\frac{\partial Q}{\partial \sigma_u^2} = -\frac{n}{2\sigma_u^2} + \frac{1}{2\sigma_u^4} (y - X\beta)'(y - X\beta) = 0 \dots (2)$$



$$\frac{\partial Q}{\partial \lambda} = -(R\beta - r) = 0 \dots (3)$$

إن ضرب المعادلة الأولى، للمشتقات الثلاثة أعلاه بـ  $R(X'X)^{-1}$  والحل من أجل  $\lambda$  يعطى:

$$\tilde{\lambda} = [\sigma_u^2 R(X'X)^{-1} R']^{-1} (R\tilde{\beta} - r) \dots (5.77)$$

حيث أن  $\tilde{\beta} = (X'X)^{-1} X'y$  هو مقدار المعقولة العظمى لـ  $\beta$ .  
وبإعادة تعويض المعادلة (5.77) بنفس المشتقة الأولى أعلاه، نجد:

$$\tilde{\beta}_R = \tilde{\beta} - (X'X)^{-1} R' [R(X'X)^{-1} R']^{-1} (R\tilde{\beta} - r) \dots (5.78)$$

حيث أن:  $\tilde{\beta}_R$  هو مقدار المعقولة العظمى المقيد.  
ومنه يكون لدينا:

$$R\tilde{\beta}_R - r = 0 \dots (5.79)$$

ومن معادلة الاشتقاق الثانية، أعلاه يمكن أن نحصل على مقدار المعقولة العظمى لـ  $\sigma_u^2$  كما يلي:

$$\tilde{\sigma}_{Ru}^2 = \frac{1}{n} (y - X\tilde{\beta}_R)' (y - X\tilde{\beta}_R) \dots (5.80)$$

$$= \frac{1}{n} \tilde{U}_R' \tilde{U}_R \dots (5.81)$$

حيث أن:

$$\tilde{U}_R = y - X\tilde{\beta}_R$$

وللبحث في خصائص  $\tilde{\theta}_R = (\tilde{\beta}_R, \tilde{\sigma}_u^2, \tilde{\lambda})$ ، نستعمل المعادلات (5.77)، (5.78)،

(5.80) من أجل اشتقاق توزيعات مقدرات المعقولة العظمى المقيدة لموجه المعالم  $\theta = (\beta, \sigma_u^2, \lambda)$ . إن  $\tilde{\beta}_R$  و  $\tilde{\lambda}$  هي دوال خطية لـ  $\tilde{\beta}$ ، ومنه:

$$\begin{pmatrix} \tilde{\beta}_R \\ \tilde{\lambda} \end{pmatrix} \sim N \left[ \begin{pmatrix} K_1 \\ K_2 \end{pmatrix}, \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \right] \dots (5.82)$$

حيث أن:

$$K_1 = \beta - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(R\beta - r)$$

$$K_2 = [\sigma_u^2 R(X'X)^{-1}R']^{-1}(R\beta - r)$$

$$A_{11} = \sigma_u^2 \left[ (X'X)^{-1} - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}R(X'X)^{-1} \right] = \text{Cov}(\tilde{\beta}_R),$$

$$A_{12} = A'_{21} = (X'X)^{-1}R'[\sigma_u^2 R(X'X)^{-1}R']^{-1} = \text{Cov}(\tilde{\beta}_R, \tilde{\lambda}),$$

$$A_{22} = [\sigma_u^2 R(X'X)^{-1}R']^{-1} = \text{Cov}(\tilde{\lambda})$$

ومنه، باستعمال المعادلة (5.82) يمكن أن نستنتج:

(a) لما  $R\beta = r$  فإن  $E(\tilde{\beta}_R) = \beta$  وكذلك  $E(\tilde{\lambda}) = 0$ ، أي أن  $\tilde{\beta}_R$  و  $\tilde{\lambda}$  هما مقدران غير متحيزين لـ  $\beta$  والصفر على الترتيب.

(b) أن  $\tilde{\beta}_R$  و  $\tilde{\lambda}$  هما مقدرين كاملي الكفاءة Fully efficient لـ  $\beta$  و  $\tilde{\lambda}$  مادام تباينيهما يحققان الحدود الدنيا لمتراجحة Cramer Rao مثلما تؤكد مباشرة مصفوفة المعلومات الموسعة:

$$I(\beta, \lambda, \sigma_u^2) = \begin{bmatrix} \frac{X'X}{\sigma_u^2} & R' & 0 \\ R & 0 & 0 \\ 0 & 0 & \frac{n}{2\sigma_u^4} \end{bmatrix} \dots (5.83)$$

(c) إن مصفوفة التباين المشترك لمقدر المعقولية العظمى المقيد  $\tilde{\beta}_R$  تكون دائما أقل أو تساوي مصفوفة التباين المشترك لمقدر المعقولية العظمى غير المقيد  $\tilde{\beta}$  مهما كانت  $R\beta = r$  أو غير ذلك، أي:

$$[\text{cov}(\tilde{\beta}_R) - \text{cov}(\tilde{\beta})] \leq 0 \dots (5.84)$$

$$[MSE(\tilde{\beta}_R) - MSE(\tilde{\beta})] \geq 0 \quad \text{ولكن}$$

حيث أن: MSE هي وسط مربع الخطأ.

وبناء على المعادلة (80.5) يمكن إعادة كتابة مقدار المعقولية العظمى لـ  $\sigma_u^2$  على الشكل:

$$\tilde{\sigma}_{uR}^2 = \tilde{\sigma}_u^2 + \frac{1}{n} (R\tilde{\beta} - r)' [R(X'X)^{-1}R']^{-1} (R\tilde{\beta} - r) \dots (5.85)$$

ومن تعريف  $\tilde{U}_R$  بالمعادلة (81.5) لدينا:

$$\tilde{U}_R = \tilde{U} - X(X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(R\tilde{\beta} - r) \dots (5.86)$$

ثم لدينا:

$$* \frac{RSS}{\sigma_u^2} = \frac{n\tilde{\sigma}_u^2}{\sigma_u^2} \sim \chi_{(n-k)}^2 \dots (5.87)$$

$$* (R\tilde{\beta} - r)' [\sigma_u^2 R(X'X)^{-1}R']^{-1} (R\tilde{\beta} - r) \sim \chi_m^2 \dots (5.88)$$

ثم لنعود للمعادلة (85.5) ونضرب طرفيها بـ  $\frac{n}{\sigma_u^2}$  لنجد:

$$\frac{n\tilde{\sigma}_{uR}^2}{\sigma_u^2} = \frac{n\tilde{\sigma}_u^2}{\sigma_u^2} + (R\tilde{\beta} - r)' [\sigma_u^2 R(X'X)^{-1}R']^{-1} (R\tilde{\beta} - r)$$

وباستعمال نتائج المعادلتين (87.5) و (88.5) تصبح المعادلة الأخيرة أعلاه:

$$\frac{n\tilde{\sigma}_{uR}^2}{\sigma_u^2} \sim \chi_{(n-k)}^2 + \chi_m^2 = \chi_{(n+m-k)}^2 \dots (5.89)$$

وواضح من التعريف الخاص ببواقي المعقولية العظمى المقيدة  $\tilde{U}_R$  بالمعادلة

(86.5) حيث أن  $\tilde{U}_R$  مستقل عن  $\tilde{U}$  نلاحظ أن:

$$E(\tilde{\sigma}_{uR}^2) \neq \sigma_u^2$$

ولكن بناء على توزيع المعادلة (89.5) ولما  $R\tilde{\beta} - r = 0$  نعرف:



$$\tilde{S}_u^2 = \frac{1}{n + m - k} \cdot \tilde{U}'_R U'_R \dots\dots\dots (5.90)$$

والتي تحقق:

$$E(\tilde{S}_u^2) = \sigma_u^2$$

ولنعود لمقدر المعقولية العظمى المقيد بالمعادلة (78.5)، وباستعمال المعادلة (82.5) نجد:

$$\begin{aligned} \tilde{\beta}_R - \tilde{\beta} &= -(X'X)^{-1} R' [R(X'X)^{-1} R']^{-1} (R\tilde{\beta} - r) \\ \tilde{\beta}_R - \beta &= (X'X)^{-1} U - (X'X)^{-1} R' [R(X'X)^{-1} R']^{-1} R(X'X)^{-1} X'U \\ \tilde{\beta}_R - \beta &= [I - (X'X)^{-1} R' (R(X'X)^{-1} R')^{-1} R] (X'X)^{-1} X'U \\ \tilde{\beta}_R - \beta &= HAU \dots\dots\dots (5.91) \end{aligned}$$

حيث أن:

$$\begin{aligned} H &= I - (X'X)^{-1} R' [R(X'X)^{-1} R']^{-1} R \\ A &= (X'X)^{-1} X' \end{aligned}$$

ومنه يكون:

$$E(\tilde{\beta}_R - \beta) = 0 \Rightarrow E(\tilde{\beta}_R) = \beta$$

أما التباين:

$$\text{var}(\tilde{\beta}_R - \beta) = \text{var}(\tilde{\beta}_R) = \sigma_u^2 H (X'X)^{-1} H' = \sigma_u^2 H (X'X)^{-1}$$

ثم لما  $n \rightarrow \infty$  تصبح:

$$\lim_{n \rightarrow \infty} [\sqrt{n}(\tilde{\beta}_R - \beta)] = 0$$

ثم لدينا:

$$\begin{aligned} \lim_{n \rightarrow \infty} \left[ \sigma_u^2 H \left( \frac{X'X}{n} \right)^{-1} \right] &= \\ \sigma_u^2 \lim_{n \rightarrow \infty} \left[ (n^{-1} X'X)^{-1} - (n^{-1} X'X)^{-1} R' (R(n^{-1} X'X)^{-1} R')^{-1} R (n^{-1} X'X)^{-1} \right] \end{aligned}$$

$$= \sigma_u^2 \left[ Q^{-1} - Q^{-1} R' [R Q^{-1} R']^{-1} R Q^{-1} \right]$$

ومنذ، نستنتج أن:

$$\sqrt{n}(\tilde{\beta}_R - \beta) \xrightarrow{D} P\eta \sim N(0, \sigma_u^2 P) \dots (5.92)$$

حيث أن:

$$P = Q^{-1} - Q^{-1} R' [R Q^{-1} R']^{-1} R Q^{-1} \dots (5.93)$$

وكذلك:

$$PQP = P$$

$$Q = \lim_{n \rightarrow \infty} (n^{-1} X'X)$$

ومنه لنعمم الفكرة بالنسبة لوجود القيود الخطية على الشكل:  $R\theta = r$ . لتكون دالة لاقرانج الموسعة لدالة المعقولية على النحو:

$$Q = \log L(\theta) - \lambda'(R\theta - r)$$

وبالإشتقاق نجد:

$$\frac{\partial Q}{\partial \theta} = D \log L(\theta) - R'\lambda = 0$$

$$\frac{\partial Q}{\partial \lambda} = -(R\theta - r) = 0$$

حيث أن  $\theta = (\beta, \lambda, \sigma_u^2)$ ، وليكون موجه مقدرات المعقولية العظمى المقيدة هو:

$$\tilde{\theta}_R = \tilde{\theta} - (X'X)^{-1} R' [R(X'X)^{-1} R']^{-1} (R\tilde{\theta} - r)$$

ونستنتج من المعادلة (92.5) أن:

$$\sqrt{n}(\tilde{\theta}_R - \theta) \xrightarrow{D} P\eta \sim N(0, P) \dots (5.94)$$

حيث أن  $P$  معرف في (93.5)، وكذلك:

$$\eta \sim N(0, Q)$$

كما أن:

$$Q = \lim_{n \rightarrow \infty} [n^{-1} I(\theta)]$$

و  $I(\theta)$  معرفة بالمعادلة (83.5).

(b) القيود غير الخطية والصحيحة على  $\beta$ :

لنأخذ حالة القيود الدقيقة وغير الخطية ونعتبر الحالة التي تكون فيها المعلومة المسبقة تأتي من موجه  $m \times 1$  لقيود غير خطية مثل:

$$\beta_1 = \beta_4 / (\beta_6 + \beta_8);$$

$$\beta_1 = -\beta_2^2;$$

$$\beta_5 \cdot \beta_3 = 1/\beta_7$$

ومنه تكون القيود على الشكل  $h_i(\beta) = 0$  حيث  $i = 1, 2, \dots, m$  ونكتبها في صيغة مصفوفات:

$$H(\beta) = 0 \dots \dots (5.95)$$

ومن أجل التأكد من الإستقلال فيما بين  $m$  قيود نفرض أن:

$$\text{Rank} \left( \frac{\partial H(\beta)}{\partial \beta} \right) = m \dots \dots (5.96)$$

ومثلما عملنا في حالة القيود الخطية نضع القيود على الشكل:

$$H_0: H(\beta) = 0$$

$$H_A: H(\beta) \neq 0$$

ولما  $H_0$  صحيحة نتوقع أن يكون  $H(\tilde{\beta}) \approx 0$  (7). ومنه يصبح الشكل هو

كيفية تكوين الاختبار الإحصائي المعتمد على المسافة:

$$\|H(\tilde{\beta}) - \theta\|^{(8)}$$

7- أنظر:

Aris SPANOS, Chap 19, Section (19.5) pages 392-402

8- أنظر نفس المرجع السابق الصفحة 428.



وبإتباع نفس الخطوات المذكورة بالفصل الثالث والرابع، يمكن تحويل المعادلة (97.5) إلى:

$$H(\tilde{\beta})' [\text{cov}(H(\tilde{\beta}))]^{-1} H(\tilde{\beta}) \dots\dots\dots (5.98)$$

إن المشكل مع العبارة (98.5) هو أننا لانعرف توزيعها ومنه لاتصلح للاختبار الإحصائي لأن توزيع  $H(\tilde{\beta})$  غير طبيعي والذي يعتبر دالة غير خطية لـ  $\tilde{\beta}$ . ولكن إذا إستطعنا تحويل  $H(\tilde{\beta})$  إلى صيغة خطية يمكن تطبيق أو إقتراح إختبار إحصائي معين مثل  $F$ .

إن تحويل  $H(\tilde{\beta})$  إلى صيغة خطية، يمكن أن يحصل عن طريق أخذ الدرجة الأولى لتوسيعات تايلور عند الموجه  $\beta$ ، أي:

$$H(\tilde{\beta}) = H(\beta) + \frac{\partial H(\beta)}{\partial \beta} (\tilde{\beta} - \beta) + R_1 \dots\dots\dots (5.99)$$

حيث  $R_1$  يمثل قيمة الحدود الباقية والتي تكون تقاربيا بجانب الصفر. إذا أهملنا كل القيم التي تأتي في الدرجة الأولى من توسيعات تايلور بالمعادلة (99.5) فإن نتائجنا المعتمدة على هذه المعادلة تكون تقاربيا صحيحة فقط. ومنه إذا كانت:

$$\sqrt{n}(\tilde{\beta} - \beta) \overset{A}{\sim} N(0, \sigma_u^2 Q^{-1}) \dots\dots\dots (5.100)$$

يمكن أن نستنتج بإستعمال المعادلة (18.5) أن:

$$\sqrt{n}[H(\tilde{\beta}) - H(\beta)] \overset{A}{\sim} N \left[ 0, \sigma_u^2 \left( \frac{\partial H(\beta)}{\partial \beta} \right) Q^{-1} \left( \frac{\partial H(\beta)}{\partial \beta} \right)' \right] \dots\dots\dots (5.101)$$

وتستلزم هذه النتيجة أنه إذا عوضنا التباين المشترك التقاربي  $[\text{cov}_A H(\tilde{\beta})]$  (بالمعادلة (98.5)) يمكن أن نحصل على توزيع تقاربي لأن:

$$nH(\tilde{\beta})' [\text{cov}_A H(\tilde{\beta})]^{-1} H(\tilde{\beta}) \sim \chi_m^2 \dots\dots\dots (5.102)$$

حيث أن:

$$\text{cov}_A(\tilde{\beta}) = \sigma_u^2 \left[ \left( \frac{\partial H(\tilde{\beta})}{\partial \beta} \right) Q^{-1} \left( \frac{\partial H(\tilde{\beta})}{\partial \beta} \right)' \right]$$

ونظرا إلى عدم معرفتنا لـ  $\beta$  و  $\sigma_u^2$  ومعرفة مثلا:  $\sigma_u^2 \xrightarrow{P} \tilde{\sigma}_u^2$  يمكن أن نكتب:

$$\tilde{\sigma}_u^2 \left[ \left( \frac{\partial H(\tilde{\beta})}{\partial \beta} \right) (n^{-1} X'X)^{-1} \left( \frac{\partial H(\tilde{\beta})}{\partial \beta} \right)' \right] \xrightarrow{P} \text{cov}_A(\tilde{\beta}) \dots (5.103)$$

حيث أن:

$$\frac{\partial H(\tilde{\beta})}{\partial \beta} = \frac{\partial H(\beta)}{\partial \beta} \Big|_{\beta=\tilde{\beta}}$$

ومنه يمكن تكوين الإختبار الإحصائي:

$$[H(\tilde{\beta})]' \left[ \tilde{\sigma}_u^2 \left( \frac{\partial H(\tilde{\beta})}{\partial \beta} \right) (X'X)^{-1} \left( \frac{\partial H(\tilde{\beta})}{\partial \beta} \right)' \right]^{-1} . H(\tilde{\beta}) \sim \chi_m^2 \dots (5.104)$$

ويمثل هذا الإختبار التقاربي إختبار Wald والذي سنتطرق إليه مع مجموعة الإختبارات المناسبة الأخرى لاحقا.

#### 4-5 إجراء الإختبارات التقاربية:

إن المشكل الأساسي لإختبار الفرضيات هو بناء إختبار إحصائي نكون نعرف توزيعه في ظل فرضيتي العدم  $H_0$  والبديل  $H_A$  ولايعتمد على موجه المعالم غير المعروفة  $\theta$ . وسوف ندرس هنا ثلاثة إختبارات مشهورة في أدبيات القياس الإقتصادي والخاصة بالعينات الكبيرة، وتستعمل هذه الإختبارات المعلومات المتعلقة بدالة لوغاريتم المعقولية. حيث تكون مختلفة في العينات الصغيرة ولكن تقاربيا تكون متكافئة.

#### 1-4-5 اختبار Wald:

إن الهدف هنا هو اختبار وجود المجموعة  $m$  من القيود الخطية والمستقلة والمكتوبة على الشكل:  $R\theta = r$ ، حيث  $\theta$  هي  $m \times 1$  موجه معالم. إن فرضيتنا الأساسية هي أنه لدينا نموذج يحقق:

$$\sqrt{n}(\tilde{\theta} - \theta) \xrightarrow{D} Q^{-1}\eta \sim N(0, Q^{-1})$$

$$Q = \lim_{n \rightarrow \infty} (n^{-1}I(\theta)) \quad \text{حيث أن:}$$

ولدينا:

$$\sqrt{n}R(\tilde{\theta} - \theta) \xrightarrow{D} RQ^{-1}\eta \sim N(0, RQ^{-1}R')$$

وتحت  $H_0$  صحيحة:  $R\theta = r$  لدينا:

$$\sqrt{n}(R\tilde{\theta} - r) \xrightarrow{D} RQ^{-1}\eta \sim N(0, RQ^{-1}R')$$

ومنه يصبح:

$$\begin{aligned} n(R\tilde{\theta} - r)'[RQ^{-1}R']^{-1}(R\tilde{\theta} - r) &\xrightarrow{D} \chi^2 \sim \chi_m^2 \\ \Rightarrow (R\tilde{\theta} - r)'[R(n^{-1}Q^{-1})R']^{-1}(R\tilde{\theta} - r) &\xrightarrow{D} \chi^2 \sim \chi_m^2 \\ \text{عمليا نعوض } n^{-1}Q^{-1} &\text{ بواسطة } I^{-1}(\tilde{\theta}). \text{ ومنه يكون الاختبار:} \end{aligned}$$

$$H_0: R\theta = r: W = (R\tilde{\theta} - r)'[RI^{-1}(\tilde{\theta})R']^{-1}(R\tilde{\theta} - r) \overset{A}{\sim} \chi_m^2 \dots (5.105)$$

إن أهم خاصية لهذا الاختبار هو أنه يعتمد مباشرة على مقدرات المعالم غير المقيدة  $(\tilde{\theta})$ . وهذا ما يميزه عن بقية الاختبارات الأخرى.



## 2-4-5 اختبار نسبة الامعقونية: "Likelihood Ratio" (L.R. Test):

لدينا القيود الخطية:  $H_0: R\theta = r$

ولتكن  $L(\tilde{\theta}_R)$  تعني نموذج المعقونية المناسب للقيود المفروضة على النموذج المدروس. و  $L(\tilde{\theta})$  هي المعقونية العظمى للنموذج غير المقيد. تكون نسبة المعقونية  $\lambda$  معرفة كمايلي:

$$\lambda = \frac{L(\tilde{\theta}_R)}{L(\tilde{\theta})}$$

حيث:  $0 \leq \lambda \leq 1$ . ومنه يكون اختبار المعقونية كمايلي:

$$LR = -2 \log \lambda = 2 \log L(\tilde{\theta}) - 2 \log L(\tilde{\theta}_R) \dots (5.106)$$

وللحصول على نهاية التوزيع لـ  $LR$  تحت  $H_0$  صحيحة نتبع خطوتين:

(1) نستعمل توسيعات سلسلة تايلور  $\log L(\tilde{\theta}_R)$  حول  $\tilde{\theta}$ .

$$\log L(\tilde{\theta}_R) \approx \log L(\tilde{\theta}) + D \log L(\tilde{\theta})' (\tilde{\theta}_R - \tilde{\theta}) + \frac{1}{2} (\tilde{\theta}_R - \tilde{\theta})' D^2 \log L(\tilde{\theta}) (\tilde{\theta}_R - \tilde{\theta})$$

إذا كانت  $H_0$  صحيحة. يجب أن تكون  $\tilde{\theta}_R$  قريبة من  $\tilde{\theta}$ . أما الحدود الباقية فتقترب من الصفر. وبمعرفة  $D \log L(\tilde{\theta}) = 0$ . تصبح:

$$LR = 2 \log(\tilde{\theta}) - 2 \log L(\tilde{\theta}_R) = (\tilde{\theta}_R - \tilde{\theta})' [-D^2 \log L(\tilde{\theta})] (\tilde{\theta}_R - \tilde{\theta})$$

$$\Rightarrow LR = (\tilde{\theta} - \tilde{\theta}_R)' [-D^2 \log L(\tilde{\theta})] (\tilde{\theta} - \tilde{\theta}_R) \dots (5.107)$$

(2) بينا من قبل أنه من أجل وجود القيود الخطية. فإن:

$$\sqrt{n}(\tilde{\theta}_R - \tilde{\theta}) \xrightarrow{D} P\eta \sim N(0, P)$$

حيث  $P$  معرفة من قبل بالمعادلة (93.5). وفي ظل  $R\theta = r$  يكون توزيع المقدر المقيد:

$$\sqrt{n}(\tilde{\theta}_R - \theta) \xrightarrow{D} P\eta \sim N(0, P)$$

$$\eta \sim N(0, Q)$$

بينما بالنسبة للمقدر غير المقيد:

$$\sqrt{n}(\tilde{\theta} - \theta) \xrightarrow{D} Q^{-1}P$$

ومن هنا نستنتج الفرق  $\sqrt{n}(\tilde{\theta} - \tilde{\theta}_R)$  على الشكل التالي:

$$\sqrt{n}(\tilde{\theta} - \tilde{\theta}_R) \xrightarrow{D} (Q^{-1} - P)\eta \sim N[0, (Q^{-1} - P)Q(Q^{-1} - P)]$$

ومن تعريف  $P$  سابقا:  $P = PQP$  نستنتج أن:

$$(Q^{-1} - P)Q(Q^{-1} - P) = Q^{-1} - P$$

حيث أن هذه المصفوفة شاذة، ولكن نعمتها بإستعمال  $\chi^2$  تحت  $H_0$ :

$$n(\tilde{\theta} - \tilde{\theta}_R)'Q(\tilde{\theta} - \tilde{\theta}_R) \xrightarrow{D} \chi^2 \sim \chi_m^2$$

لأن  $Q$  هي المقلوب العام لـ  $(Q^{-1} - P)$  ومنه نكتب صيغة الاختبار:

$$LR = n(\tilde{\theta} - \tilde{\theta}_R)'[-n^{-1}D^2 \log L(\tilde{\theta})].(\tilde{\theta} - \tilde{\theta}_R) \sim \chi_m^2 \dots \dots (5.108)$$

### 3-4-5 اختبار مضاعف لاغرانج "Lagrange Multiplier" (L.M Test):

لنفرض أنه لدينا مجموعة من القيود الخطية تحت  $H_0$  ويكون الاختبار

كما يلي:

$$L.M = D \log L(\tilde{\theta}_R)'[I(\tilde{\theta}_R)]^{-1}.D \log L(\tilde{\theta}_R) \dots \dots (5.109)$$

إذا كانت  $H_0$  صحيحة نتوقع أن تقترب  $\tilde{\theta}_R$  حول  $\tilde{\theta}$ ، ومنه فإن توسيعات سلسلة تايلور  $D \log L(\tilde{\theta}_R)$  حول  $\tilde{\theta}$  تعطى بالتعريف كما يلي:

$$D \log L(\tilde{\theta}_R) \approx D \log L(\tilde{\theta}) + D^2 \log L(\tilde{\theta})(\tilde{\theta}_R - \tilde{\theta})$$

و ما دام  $D \log L(\tilde{\theta}) = 0$  تصبح:

$$D \log L(\tilde{\theta}_R) \approx D^2 \log L(\tilde{\theta})(\tilde{\theta}_R - \tilde{\theta})$$

لينتج:

$$L.M = (\tilde{\theta}_R - \tilde{\theta})' D^2 \log L(\tilde{\theta})' [I(\tilde{\theta}_R)]^{-1} \cdot D^2 \log L(\tilde{\theta}) \cdot (\tilde{\theta}_R - \tilde{\theta})$$

$$LM = (\tilde{\theta} - \tilde{\theta}_R)' D^2 \log L(\tilde{\theta})' [I(\tilde{\theta}_R)]^{-1} \cdot D^2 \log L(\tilde{\theta}) \cdot (\tilde{\theta} - \tilde{\theta}_R) \dots (5.110)$$

ونخلص القول إلى أن <sup>(9)</sup>:

$W$  = يحتوي على مقدرات غير مقيدة فقط  $H_A$ .

$LM$  = يحتوي على مقدرات مقيدة فقط  $H_0$ .

$LR$  = يحتوي على كليهما.

$$W \geq LR \geq LM$$

<sup>9</sup>- للتعمق أكثر في:

\* A.C HARVEY 1981. Chap 5. pages 144-187 (مرجع سابق)

\* L.G Gold Frey 1988: "Mispecification Tests in Econometrics" Cambridge University Press Chapters 1,2,3.



## 5-5 التقدير بالمتغيرات الأدواتية "Instrumental Variable Estimation" (I.V.E)

بالرغم من أن التقدير بطريقة المعقولية العظمى يوفر عدة مزايا نظرية، فإن تلك الخصائص المحصل عليها تعتمد على فرضيات تخصيص النموذج الكامل والخالي من أخطاء التخصيص التي تواجهنا في الحياة الميدانية، حيث نادرا ما يكون ذلك صحيحا. ونظرا للمشاكل الناتجة عن ذلك فإننا نعتبر الطريقة البديلة والمعتمدة على المتغير الأدواتي والتي تتحاشى المشاكل التي تنتج (تظهر) لما تكون بعض المحددات مرتبطة في نهايتها مع وحدات (عناصر) موجه الأخطاء. ولنفرض النموذج الخطي العام:

$$Y = X\beta + U$$

$$U_i \sim \text{I.I.D}(0, \sigma_u^2) \quad \text{مع الأخطاء:}$$

حيث أن عمودا أو أكثر من أعمدة  $X$  تحتوي على عناصر عشوائية، ومنه نفرض أن:

$$\text{i) } p \lim(n^{-1} X'X) = Q$$

$$\text{ii) } p \lim(n^{-1} X'U) = q$$

حيث أن  $Q$  مصفوفة غير شاذة. وعندما يكون عمود أو أكثر من أعمدة  $X$  مرتبطا بالنهاية مع الأخطاء تكون:

$$p \lim[n^{-1} \sum X_{ji} U_i] \neq 0$$

ومنه فإن  $q$  ليست موجه أصفار، وتكون مقدرات المربعات الصغرى العادية غير متسقة. وللحصول على مقدار متسق، يمكن أن نفرض بأن  $W$  ( $n \times p$ ) مصفوفة متغيرات مستقلة بحيث أن  $p \geq k$  وكذلك تحقق:

$$a. \text{plim}(n^{-1}W'U) = 0$$

$$b. \text{plim}(n^{-1}W'X) = Q_{wx}$$

$$c. \text{plim}(n^{-1}W'W) = Q_{ww}$$

حيث أن  $Q_{ww}$  مصفوفة غير شاذة،  $\text{Rank}(Q_{ww}) = K$ .

يتطلب الشرط الأول (a) بأن تكون أعمدة  $W$  غير مرتبطة مع  $U$  نهائيا. أما الشرط الثاني (b) فهو أكثر تقنية، حيث يتطلب بعض الارتباط النهائي بين مصفوفتي المتغيرات المستقلة  $X$  و  $W$ . أما الشرط الثالث (c)، فيهتم بتقارب عزوم العينة لمجموعة المتغيرات المحددة والمطبقة هنا على المتغيرات في  $W$ . ولنعتبر الآن تقنية التقدير بواسطة المتغيرات الأدواتية (IVE). وعوضا عن تحديد  $y$  في  $X$ ، فإتينا أولا، نحدد المتغيرات  $X$  في المتغيرات  $W$ ، ثم نأخذ القيم التقديرية  $\hat{X}$ . ثم نحدد  $y$  في  $\hat{X}$ ، بدلا من  $X$ ، لنحصل على مقدر المتغيرات الأدواتية  $\beta$ . بحيث يجب أن تكون  $W'W$  غير شاذة. ويجري التقدير كمايلي:

في النموذج الخطي العام  $v = X\beta + U$ ، نحدد المتغيرات  $X$  في المتغيرات الأدواتية  $W$  كمايلي:

$$X = W\gamma + U \dots (5.111)$$

ثم بتطبيق المربعات الصغرى على النموذج (5.111) نجد:

$$X = Wb + \hat{U} = \hat{X} + \hat{U}$$

ولنضرب هذه النتيجة الأخيرة بمصفوفة المتغيرات الأدواتية  $W'$  لنجد:

$$b = (W'W)^{-1}W'X \dots (5.112)$$

ولتصبح لدينا:  $\hat{X} = Wb = W(W'W)^{-1}W'X = P_w X$

حيث أن:  $P_w = W(W'W)^{-1}W'$

ثم نحدر  $y$  في مصفوفة القيم التقديرية  $\hat{X}$  لنحصل على مقدار المتغيرات الأدواتية كمايلي:

$$y = \hat{X}\beta + U \Rightarrow \tilde{y} = \hat{X}\tilde{b}$$

$$y = \tilde{y} + \tilde{U} = \hat{X}\tilde{b} + \tilde{U}$$

$$\hat{X}'y = \hat{X}'\hat{X}\tilde{b} + \hat{X}'\tilde{U}$$

$$\tilde{b} = (\hat{X}'\hat{X})^{-1} \hat{X}'y$$

ومن تعريف  $\hat{X} = P_w X$ ، ينتج لدينا  $P_w = P_w' = P_w' P_w$ ، ويكون مقدار المتغيرات الأدواتية  $\tilde{b}$  على الشكل التالي:

$$\tilde{b} = (X'P_w'P_wX)^{-1} \cdot X'P_w'y \dots\dots\dots (5.113)$$

أو على النحو:

$$\tilde{b} = [X'W(W'W)^{-1}W'X]^{-1} X'W(W'W)^{-1}W'y \dots\dots\dots (5.114)$$

وإذا كانت أعمدة المصفوفة  $W$  متساوية مع أعمدة  $X$  فإن  $\text{Rank}(WX) = k$  ومنه يكون مقدار المتغيرات الأدواتية على الشكل:

$$\tilde{b} = (W'X)^{-1} W'y \dots\dots\dots (5.115)$$

وهو الشكل المختصر للمعادلة (114.5) حيث نسمي مقدار المتغيرات الأدواتية بالمعادلة (115.5) بمقدار المتغيرات الأدواتية البسيط.

### مثال (3.5)

للتعرف على كيفية اختبار المتغيرات الأدواتية، نعتبر دالة الإستهلاك الكينزية مع معادلة تعريف الدخل كمايلي:

$$C_t = \alpha + \beta Yd_t + u_t$$

$$Yd_t = C_t + Z_t$$

حيث أن:



$$C_t = \text{الإنفاق الإستهلاكي}$$

$$Yd_t = \text{الدخل المتاح (مجموعات الإنفاق الإستهلاكي وغير الإستهلاكي - ضرائب الدخل)}.$$

$$Z_t = \text{الإنفاق غير الإستهلاكي - الضرائب على الدخل}.$$

ومادامت  $C_t$  تعتمد على  $u_t$  و  $Yd_t$  تعتمد على  $C_t$ ، نستنتج أن  $u_t$  و  $Yd_t$  مرتبطين وتحت الفرضيات الأساسية المعروفة نحصل من تطبيق قانون المربعات الصغرى العادية على هذا النموذج، على مقدرات غير متسقة لكل من  $\alpha$  و  $\beta$ . إذا اعتبرنا  $Z_t$  متغير خارجي، فإن الملاحظات  $Z_t$  يمكن إعتبارها غير عشوائية (أي مثبتة). وإذا وضعنا فرضيات أساسية حول تقارب المقدار  $n^{-1} \sum_{t=1}^n Z_t^2$  فإنه

ينتج:

$$\text{plim} \left( n^{-1} \sum_{t=1}^n Z_t U_t \right) = 0$$

إن هذا معناه أن  $Z_t$  هي المتغيرة الأدواتية المناسبة، ومنه فإنه يمكن الحصول على مقدر المتغيرات الأدواتية (I.V.E). أولا عن طريق تحديد  $Yd_t$  في  $Z_t$  مع حد ثابت وأخذ القيم التقديرية  $\hat{Y}d_t$ . ثم نحدر  $C_t$  في  $\hat{Y}d_t$  مع حد ثابت للحصول على مقدر المتغيرات الأدواتية لـ  $\alpha$  و  $\beta$ .

### 1-5-5 الخصائص الإحصائية لمقدر المتغيرات الأدواتية:

بتوفر الشروط الثلاثة  $a$ ،  $b$ ،  $c$ ، المذكورة سابقا يمكن أن نبين بأن مقدر المتغيرات الأدواتية،  $\tilde{b}$ ، متسق حيث لدينا:

$$\begin{aligned} \tilde{b} &= [X'W(W'W)^{-1}W'X]^{-1} X'W(W'W)^{-1}W'y \\ &= \beta + [X'W(W'W)^{-1}W'X]^{-1} X'W(W'W)^{-1}W'U \end{aligned}$$

$$\tilde{b} = \beta + [(n^{-1}X'W)(n^{-1}W'W)^{-1}(n^{-1}W'X)]^{-1} (n^{-1}X'W)(n^{-1}W'W)^{-1} (n^{-1}W'U)$$

و ما دام كل حد على حده للمعادلة أعلاه له نهاية إحتمال معروفة فإن:

$$p \lim(\tilde{b}) = \beta + [Q'_{WX} \cdot Q_{WW}^{-1} \cdot Q_{WX}]^{-1} Q'_{WX} \cdot Q_{WW}^{-1} \cdot 0 = 0 \\ \Rightarrow p \lim(\tilde{b}) = \beta$$

ومنه نقول، عند الحصول على المتغيرات الأدواتية المناسبة، فإن  $\tilde{b}$  يكون متسقاً،

ولنفرض أن  $\left( \frac{1}{\sqrt{n}} W'U \right)$  تتقارب بالتوزيع إلى الموجه العشوائي  $\eta$  كمايلي:

$$n^{-1/2} W'U \xrightarrow{D} \eta \sim N(0, \sigma_u^2 Q_{WW})$$

وباستعمال المعادلة (18.5) -نظرية Cramer- ينتج:

$$\sqrt{n}(\tilde{b} - \beta) \xrightarrow{D} [Q'_{WX} \cdot Q_{WW}^{-1} \cdot Q_{WX}]^{-1} Q'_{WX} \cdot Q_{WW}^{-1} \cdot \eta \dots (5.116)$$

$$\sqrt{n}(\tilde{b} - \beta) \sim N[0, \sigma_u^2 (Q'_{WX} \cdot Q_{WW}^{-1} \cdot Q_{WX})^{-1}] \dots (5.117)$$

رغم أن مصفوفة التباين أعلاه تظهر معقدة، فإنه ليس صعباً تطبيق هذه النتيجة

على العينات الكبيرة النهائية لأن المقدار  $[Q'_{WX} \cdot Q_{WW}^{-1} \cdot Q_{WX}]$  هو نهاية

الإحتمال للعبارة  $[n^{-1} \hat{X}' \hat{X}]$  ومنه فإنه عند العينات الضخمة والمتناهية يكون:

$$\tilde{b}^A \sim N[\beta, \sigma_u^2 n^{-1} (Q'_{WX} \cdot Q_{WW}^{-1} \cdot Q_{WX})^{-1}] \dots (5.118)$$

ومن ثم يمكن تعويض المقدار  $[(Q'_{WX} \cdot Q_{WW}^{-1} \cdot Q_{WX})^{-1}]$  بالمقدار المتسق

$$[(\tilde{n} \hat{X}' \hat{X})^{-1}] \text{ ليعطي:}$$

$$\tilde{b}^A \sim N[\beta, \sigma_u^2 (\hat{X}' \hat{X})^{-1}] \quad n \rightarrow \infty \dots (5.119)$$

والحصول على نتيجة عملية يجب تعويض  $\sigma_u^2$  بمقدر متسق:

$$\tilde{\sigma}_{IVE}^2 = \sum_{t=1}^n \tilde{U}_t^2 / (n - k) \dots (5.120)$$

أو على الشكل:



$$\tilde{\sigma}_{VE}^2 = \sum_{i=1}^n \tilde{U}_i^2 / n \dots (5.121)$$

حيث أن  $\tilde{U}_i$  هو بواقي المتغيرات الأدواتية ويعرف كمايلي:

$$\tilde{U} = Y - X\tilde{b} \dots (5.122)$$

### 2-5-5 حساب بواقي المتغيرات الأدواتية:

من الواضح أننا نحصل على مقدرات المتغيرات الأدواتية بواسطة تحديد  $X$  في المتغيرات الأدواتية  $W$ ، ثم الحصول على القيم التقديرية  $\hat{X}$ . بعدها نحدر  $Y$  في هذه القيم التقديرية  $\hat{X}$ . إن هذه الطريقة تعطي مقدرات المتغيرات الأدواتية الحقيقية والصحيحة، لكن بعض النتائج الإحصائية تكون غير صحيحة مادامت الخطوة الثانية للإتحاد تحسب أوتوماتيكيا البواقي على الشكل التالي:

$$\hat{U} = y - \hat{X}\tilde{b} \dots (5.123)$$

بينما بواقي المتغيرات الأدواتية الصحيحة هي:

$$\tilde{U} = y - X\tilde{b} \dots (5.124)$$

حيث عوضنا في المعادلة (124.5)  $\hat{X}$  بقيمتها الأصلية من أجل الحصول على موجه البواقي  $\hat{U}$ . فإذا طبقنا طريقة المربعات الصغرى العادية مرتين، تكون البواقي كما في المعادلة (123.5)، ومنه فإن النتائج الإحصائية  $SE(\cdot)$  الاختبار  $t$ ، معامل التحديد المضاعف  $R^2$ ، ومقاييس إحصائية أخرى تكون محسوبة بطريقة غير صحيحة. وبواسطة برنامج خاص ومخصص مباشرة لطريقة التقدير بواسطة المتغيرات الأدواتية، أو طريقة خطوتين للمربعات الصغرى (2SLS)، يمكن من حساب البواقي بطريقة صحيحة كما في المعادلة (124.5).



### 3-5-5 القيود الخطية الصحيحة:

لنعتبر مشكلة إختبار مجموعة  $m$  من القيود الخطية والمستقلة والمكتوبة على الشكل:  $R\beta = r$ . ولما تكون مقدرات المعالم محصل عليها بطريقة المتغيرات الأدواتية نعرف:

$$A = [Q'_{WX} \cdot Q^{-1}_{WW} \cdot Q_{WX}]^{-1} \cdot Q'_{WX} \cdot Q^{-1}_{WW}$$

ومنه تصبح:

$$\sqrt{n}(\tilde{b} - \beta) \xrightarrow{D} A\eta \sim N(0, \sigma_u^2 A Q_{WW} A')$$

وبإدخال القيود الخطية  $R\beta = r$ ، فإن:

$$\sqrt{n}R(\tilde{b} - \beta) \xrightarrow{D} RA\eta \sim N(0, \sigma_u^2 RA Q_{WW} A' R')$$

وتحت  $H_0$  صحيحة ( $R\beta = r$ ) تصبح:

$$\sqrt{n}(R\tilde{b} - r) \xrightarrow{D} RA\eta \sim N(0, \sigma_u^2 RA Q_{WW} A' R') \dots (5.125)$$

ومنه يكون:

$$n(R\tilde{b} - r)' [RA Q_{WW} A' R']^{-1} (R\tilde{b} - r) / \sigma_u^2 \xrightarrow{D} \chi^2 \sim \chi_m^2 \dots (5.126)$$

حيث أن:  $\text{plim} \left( \frac{\hat{X}'\hat{X}}{n} \right)^{-1} = A Q_{WW} A'$  ومنه تكون (5.126) في العينات الكبيرة وفي ظل القيود الخطية  $H_0: R\beta = r$  على الشكل:

$$(R\tilde{b} - r)' [R(\hat{X}'\hat{X})^{-1} R']^{-1} (R\tilde{b} - r) / \sigma_u^2 \xrightarrow{A} \chi_m^2 \dots (5.127)$$

#### 5-5-4 حساب الإختبارات الإحصائية في ظل القيود الخطية $R\beta = r$ :

إن الإختبار الإحصائي بالمعادلة (127.5)، يتشابه مع ذلك المحصل من طريقة التقدير بواسطة المربعات الصغرى العادية بالفصل الثالث. حيث تقوم طريقة المربعات الصغرى العادية بتصغير العبارة:

$$S(\beta) = (y - X\beta)'(y - X\beta)$$

تبعاً للقيود الخطية وموجه المعالم  $\beta$ . بينما تقوم طريقة المتغيرات الأدواتية بتصغير العبارة:

$$\begin{aligned} S_{IV}(\beta) &= (y - X\beta)' W(W'W)^{-1} W'(y - X\beta) \\ &= (y - X\beta)' P_w (y - X\beta) \dots (5.128) \end{aligned}$$

وتعطي الشروط الأولى لتصغير العبارة (128.5) ما يلي:

$$X'P_w(y - X\beta) = 0$$

والقيمة المحققة لهذه المساواة أعلاه هي مقدار المتغيرات الأدواتية  $\tilde{b}$ . حيث أن شروط التعامد لمقدار المتغيرات الأدواتية غير المقيد هي:

$$X'P_w \tilde{U} = \hat{X}' \tilde{U} = 0$$

و  $\tilde{U}$  معرف بالمعادلة (122.5) وهو موجه بواقى المتغيرات الأدواتية غير المقيدة. وإذا قمنا بتصغير العبارة (128.5) تبعاً للقيود  $R\beta = r$ . فمن الممكن الحصول على مقدار المتغيرات الأدواتية المقيد (RIVE) على الشكل:

$$\tilde{b}_R = \tilde{b} - (\hat{X}'\hat{X})^{-1} R' [R(\hat{X}'\hat{X})^{-1} R']^{-1} (R\tilde{b} - r) \dots (5.129)$$

ومنه لنعتبر أن  $\tilde{U}_R$  هو بواقى المتغيرات الأدواتية المقيدة (RIVR) يكون:

$$\tilde{U}_R = y - X\tilde{b}_R = \tilde{U} - X(\hat{X}'\hat{X})^{-1} R' [R(\hat{X}'\hat{X})^{-1} R']^{-1} (R\tilde{b} - r) \dots (5.130)$$

ولما نكون مجموع المربعات  $\tilde{U}'_R \cdot \tilde{U}_R$ ، فإن ضرب الحدود المتقاطعة ليمين المعادلة (130.5) لا تختفي مادام  $X' \tilde{U} \neq 0$ ، ومنه فإن الفرق:

$$\tilde{U}'_R \tilde{U}_R - \tilde{U}' \tilde{U} \neq (R\tilde{b} - r)' [R(\hat{X}'\hat{X})^{-1}R']^{-1} (R\tilde{b} - r) \sim \chi_m^2$$

وللحصول على تانون يشبه ذلك المحصل عليه من طريقة المربعات الصغرى. يجب الاعتماد على دالة الأخطاء لطريقة المتغيرات الأدواتية وهي:

$$S_{IV}(\beta) = (y - X\beta)' P_W (y - X\beta)$$

إن مجموع المربعات المناسبة لهذه الدالة يجرأ كما يلي:

$$\tilde{U}'_R P_W \tilde{U}_R = \tilde{U}' P_W \tilde{U} + (R\tilde{b} - r)' [R(\hat{X}'\hat{X})^{-1}R']^{-1} (R\tilde{b} - r)$$

ومنه يمكن حساب المعادلة:

$$(R\tilde{b} - r)' [R(\hat{X}'\hat{X})^{-1}R']^{-1} (R\tilde{b} - r) / \sigma_u^2 \sim \chi_m^2$$

كما يلي:

$$S_{IV}(\tilde{b}_R) - S_{IV}(\tilde{b}) = \tilde{U}'_R P_W \tilde{U}_R - \tilde{U}' P_W \tilde{U}$$

لنحصل في الأخير على:

$$\frac{S_{IV}(\tilde{b}_R) - S_{IV}(\tilde{b})}{\sigma_u^2} \sim \chi_m^2$$



## 6-5 سلسلة تمارين حول الفصل الخامس

### التمرين الأول:

لتكن  $\hat{\theta}_n$  مقدرة  $\theta$ . وليكن خطأ المعاينة من الشكل:

$$\hat{\theta}_n - \theta = [\hat{\theta}_n - E(\hat{\theta}_n)] + [E(\hat{\theta}_n) - \theta] = a_n + b_n$$

(a) إذا كانت السلسلة العشوائية  $a_n$  لها نهاية احتمال معروفة ونهائية، والسلسلة غير العشوائية  $b_n$  لها كذلك نهاية معرفة، فأثبت أن:

$$\text{plim}(a_n + b_n) = \text{plim}(a_n) + \text{plim}(b_n)$$

(b) إذا كان  $\hat{\theta}_n$  متحيزاً، فبين بأن التحيز يتقارب إلى الصفر لما  $n \rightarrow \infty$ .

(c) بناءً على (b)، أعلاه، بين بأن تباين  $\hat{\theta}_n$  يتقارب إلى الصفر لما  $n \rightarrow \infty$ .

(d) بناءً على نتائجك في (b) و (c)، بين بأن  $\hat{\theta}_n$  هو مقدر متنسق لـ  $\theta$ .

### التمرين الثاني:

لتكن لدينا العينة العشوائية للملاحظات المستقلة في  $y_i$  حيث

$$i = 1, 2, \dots, n$$

(a) إذا كانت  $y_i \sim N(0, \sigma^2)$ . أوجد مقدر المعقولية العظمى لـ  $\sigma^2$  وتوزيعه التقاربي.

(b) إذا كانت  $y_i \sim N(0, 1)$ . أوجد مقدر المعقولية العظمى لـ  $\theta$  وتوزيعه التقاربي.

(c) بناءً على التوزيع  $y_i$  في (b) أعلاه، بين صحة العبارة التالية:

$$E\left[\frac{\partial \log L(\theta, Y)}{\partial \theta}\right]^2 = -E\left[\frac{\partial^2 \log L(\theta, Y)}{\partial \theta^2}\right] = -E\left[\frac{\partial^2 \log L(\theta, Y)}{\partial \theta^2}\right]$$

- (d) إذا كانت  $y_i \sim N(\theta_i, \sigma^2)$  . اشتق مقدرات المعقولة العظمى المناسبة لـ  $(\sigma^2, \theta_1, \theta_2, \dots, \theta_n)$  وتوزيعها التقاربي.
- (e) إذا كانت  $y_i \sim N(\theta_i, \sigma_i^2)$  . اشتق مقدرات المعقولة العظمى المناسبة لـ  $(\sigma^2, \theta_1, \theta_2, \dots, \theta_n)$  وتوزيعها التقاربي.
- (f) قارن مابين مفهومي التقارب بالإحتمال والتقارب بالتوزيع.

### التمرين الثالث:

لنعتبر النموذج الخطي التالي:

$$y_i = \theta_1 X_{1i} + u_i$$

$$u_i \sim NI(0, \sigma_u^2)$$

$$\theta = (\theta_1, \sigma_u^2)$$

- (a) عرف مقدر المربعات الصغرى العادية ومقدر المعقولة العظمى لـ  $\theta$ .
- (b) قارن خصائص المقدرين في (a) أعلاه.
- (c) بين بأن  $\text{var}(\hat{\theta}_1) = \sigma_u^2 / \sum X_{1i}^2$  . وقارنه مع الحد الأدنى لمتراجحة كرامر-رو. حيث أن  $\hat{\theta}$  هو مقدر المربعات الصغرى العادية.
- (d) إذا أضفنا الحد الثابت،  $\theta_0$ ، للنموذج الخطي أعلاه. أوجد مصفوفة المعلومات للمعالم  $\theta = (\theta_0, \theta_1, \sigma_u^2)$ .

### التمرين الرابع:

- لتكن لدينا السلسلتين العشوائيتين  $Y_n, Z_n, n > 1$ .
- (a) بين بأنه إذا كانت  $Y_n \xrightarrow{P} b, Z_n \xrightarrow{P} c$ ،  $c$  ثابتين فإنه يستلزم ذلك أن:  $Y_n - Z_n \xrightarrow{P} b - c$ .

(b) لتكن الآن  $y_1, Z_1$  موجهين عشوائيين طبيعيين. بين بأن التوفيق الخطي  $A_1 y_1 + B_1 Z_1$  يكون موجهها طبيعيا مستعملا في ذلك الدوال المميزة.

(c) بين بأنه إذا كانت  $y_1$  موجهها عشوائيا متعددًا، فإن دالته المميزة تعطي بالعبارة:

$$\phi_{y_1}(t) = \exp \left[ i\mu't - \frac{1}{2} t' \Sigma t \right]$$

(d) بين أنه إذا كانت  $y_i$  عبارة عن موجهات عشوائية موزعة تماثلًا وإستقلًا، كل واحد منها بوسط  $\mu$ ، ومصفوفة تباين هي  $\Sigma$  فإن:

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n (y_i - \mu) \xrightarrow{D} \eta \sim N(0, \Sigma)$$

حيث أن  $\eta$  هو توزيع طبيعي متعدد.

### التمرين الخامس:

ليكن النموذج الخطي العام على الشكل  $Y = X\beta + U$  مع مجموعة القيود الخطية  $R\beta = r$  حيث  $R$  و  $r$  هي  $m \times k$ ،  $m \times 1$  على الترتيب للقيود المناسبة.

(a) أوجد مقدر المعقولة العظمى المقيد  $\tilde{\beta}_R$ . بين بأنه مقدر غير متحيز وأوجد تباينه.

(b) ليكن  $\tilde{\beta}_R$  و  $\tilde{\lambda}$  مقدري المعقولة العظمى المقيد ومضاعفات لاغرانج على الترتيب. وإذا كانت:

$$\begin{pmatrix} \tilde{\beta}_R \\ \tilde{\lambda} \end{pmatrix} \sim N \left[ \begin{pmatrix} c_1 \\ c_2 \end{pmatrix}, \begin{bmatrix} A & B \\ B' & D \end{bmatrix} \right],$$

أوجد العناصر:  $A, B, D, c_1, c_2$ .

(c) اشتق مصفوفة المعلومات  $I(\beta, \lambda, \sigma_u^2)$ .

(d) بإستعمال قانون المعكوس المجزء:



$$\begin{bmatrix} A & B \\ B' & D \end{bmatrix}^{-1} = \begin{bmatrix} A^{-1} + FE^{-1}F' & -FE^{-1} \\ -E^{-1}F' & E^{-1} \end{bmatrix}$$

حيث أن:  $E = D - B'A^{-1}B$ ,  $F = A^{-1}B$

إشتق معكوس مصفوفة المعلومات  $I^{-1}(\beta, \lambda, \sigma_u^2)$ . وقارن مختلف عناصرها مع العناصر  $A$ ,  $B$ ,  $D$  في الفرع (b) أعلاه.

(e) بين بأن متراجحة كرامر-رو للحد الأدنى تحققها مصفوفة المعلومات  $I(\beta, \lambda, \sigma_u^2)$ .

(f) لتكن  $\tilde{U}_R$  بواقي المعقولة العظمى المقيدة،  $\tilde{U}$  بواقي المعقولة العظمى غير المقيدة. تأكد أن:

$$\tilde{U}_R' \tilde{U}_R - \tilde{U}' \tilde{U} = (R\tilde{\beta} - r)' [R(X'X)^{-1}R']^{-1} (R\tilde{\beta} - r)$$

(g) لتكن  $\tilde{\sigma}_R^2$  هي مقدار المعقولة العظمى المقيد لـ  $\sigma_u^2$ . تأكد من صحة العبارة:

$$\frac{n\tilde{\sigma}_R^2}{\sigma_u^2} = \frac{\tilde{U}_R' \tilde{U}_R}{\sigma_u^2} \sim \chi_{(n+m-k)}^2$$

(h) بين بأن:  $\sqrt{n}(\tilde{\beta}_R - \beta) \xrightarrow{D} P\eta \sim N(0, P)$

حيث أن:  $\eta \sim N(0, Q)$

$$P = Q^{-1} - Q^{-1}R'[RQ^{-1}R']^{-1}RQ^{-1}$$

$$PQP = P$$

$$Q = \lim_{n \rightarrow \infty} (n^{-1}X'X)$$

(i) من أجل القيود الخطية  $R\beta = r$ ، كون الإختبارات الإحصائية الثلاثة: Wald، LR، LM وأجري مقارنة فيما بينها.

### التمرين السادس:

لنعتبر النموذج الخطي:  $Y_i = X_{1i}\theta_1 + X_{2i}\theta_2 + u_i$  مع الفرضيات  
 $i = 1, 2, \dots, n$  .  $\text{var}(U) = \sigma_u^2 I_n$  .  $E(U_i) = 0$

(a) تأكد من أن مقدار المربعات الصغرى العادية لـ  $\theta$  المقيدة. لما  $\theta_1 = 0$  هو:

$$\hat{\theta}_{RR} = 0$$

$$\hat{\theta}_{RR} = \hat{\theta}_2 + (X_2'X_2)^{-1}X_2'X_1\hat{\theta}_1$$

(b) إذا أصبح النموذج أعلاه على الشكل:  $Y_i = X_i\theta + u_i$  حيث أن المعلمة  $\theta$  مقيدة بالعلاقة  $R\beta = r$ . ولنفرض أن الزوج  $(U_i, X_i)$  مستقل ويحقق  $E(U/X) = 0$  .  $\text{var}(U/X) = \sigma_u^2$  . استعمل عبارتي المقدّر  $\hat{\theta}_R$  وموجه المقدّر لمضاعفات لاغرانج  $\tilde{\lambda}$  لتبين بأن هذين الأخيرين يتقاربان في العينات الكبيرة إلى كل من  $\theta$  و  $0$  على الترتيب.

(c) لنعتبر الآن نموذج العينة من الشكل  $Y_i \sim N(0, \Sigma)$  حيث أن الموجه  $\theta = (\theta_1, \theta_2)$  غير معروف بينما المصفوفة  $\Sigma$  معروفة. ماهو مقدار المعقولية العظمى غير المقيد لـ  $\theta_1$ . وإذا كان  $\theta_2 = 0$  فماهو مقدار المعقولية لـ  $\theta_1$  كذلك وماهو توزيعه في هذه الحال؟

### التمرين السابع:

في النموذج الخطي العام:

$$Y = X\beta + U$$

$$E(UU') = \sigma_u^2 I_n$$

(a) إذا كانت  $X$  عشوائية، لكن  $\text{plim}(n^{-1}X'X)$  موجودة كمصفوفة غير شاذة وكذلك لدينا  $\text{plim}(n^{-1}X'U) = 0$  بين أن:  $\text{plim}(\hat{\beta}) = \beta$  حيث  $\hat{\beta}$  هو مقدر المربعات الصغرى العادية.

(b) إذا كانت كذلك  $\text{plim}(n^{-1}U'U) = \sigma_u^2$  بين أن  $\hat{\sigma}_u^2 = \hat{U}'\hat{U}/(n-k)$  و  $\tilde{\sigma}_u^2 = \hat{U}'\hat{U}/n$  كليهما مقدر متنسق لـ  $\sigma_u^2$ .

(c) إذا أعدنا كتابة النموذج أعلاه على الشكل  $Y = X\beta + U = i\beta_1 + X_0\beta_* + U$  نستعمل التقدير بواسطة المتغيرات الأدواتية، حيث أن المصفوفة الأدواتية  $Z$  هي  $n \times k$  ومجزأة مثل  $Z = [i \quad Z_*]$  بين أن:

$$\tilde{b}_* = (Z_*'M_0X_0)^{-1}Z_*'M_0Y$$

(d) إذا أصبح لدينا النموذج السلمي التالي:

$$Y_t = \alpha + \beta X_t + u_t; \quad t = 1, 2, \dots, n$$

$$E(X_t u_t) \neq 0$$

بحيث أن التقدير بواسطة المربعات الصغرى العادية، أصبح غير متنسق. وإذا كان:

$$\text{plim}[n^{-1}(X_t - \bar{X})(u_t - \bar{u})] = E(X_t u_t)$$

$$\text{plim}[n^{-1}(X_t - \bar{X})^2] = \text{var}(X_t)$$

بين أن اتجاه عدم الإتساق (أي إشارة  $\text{plim}(\hat{\beta} - \beta)$ ) يعتمد على إشارة  $\text{cov}(X_t, u_t)$ .

(e) لتكن  $X_t$  في العلاقة (d) عبارة عن سلسلة من المتغيرات العشوائية الموزعة تماثلًا وإستقلاليًا مع:

$$X_t \sim \text{IID}(\mu, \sigma_X^2)$$

باستعمال الشروط الضرورية للتقارب الإحتمالي (بالإحتمال)، بين أن:



$$p \lim(\bar{X}_m) = p \lim(n^{-1} \sum_{i=1}^n X_i) = \mu$$

(f) إشرح كيف أن مقدار المعقولة العظمى لـ  $\sigma_u^2$  في النموذج الخطي العام أعلاه، قادر على تحقيق الحد الأدنى لمراجعة كرامر-رو. بين دور مصفوفة المعلومات في التقدير بواسطة المعقولة العظمى.

(g) في عينة من 21 ملاحظة مناسبة لنموذج تحديد الدخل:

$$C_i = \alpha + \beta Y_i + u_i$$

$$Y_i = C_i + I_i$$

حصلنا على النتائج:

$$\sum (C_i - \bar{C})(Y_i - \bar{Y}) = 9 \quad \sum (Y_i - \bar{Y})^2 = 12$$

$$\sum (I_i - \bar{I})^2 = 1 \quad \sum (C_i - \bar{C})(I_i - \bar{I}) = 2$$

$$\sum (Y_i - \bar{Y})(I_i - \bar{I}) = 3,$$

قدر  $\beta$  بواسطة المربعات الصغرى، ثم استعمل  $I_i$  كمتغير أداتي. علق على نتائجك بناءا على العلاقة (d) أعلاه.

## ملحق الجداول الإحصائية

جدول 1: مساحات التوزيع الطبيعي المعياري

z	.00	.01	.02	.03	.04	.05	.06	.07	.08	.09
0.0	.0000	.0040	.0080	.0120	.0160	.0199	.0239	.0279	.0319	.0359
0.1	.0398	.0438	.0487	.0517	.0557	.0596	.0636	.0675	.0714	.0753
0.2	.0793	.0832	.0871	.0910	.0948	.0987	.1026	.1064	.1103	.1141
0.3	.1179	.1217	.1255	.1293	.1331	.1368	.1406	.1443	.1480	.1517
0.4	.1554	.1591	.1628	.1664	.1700	.1736	.1772	.1808	.1844	.1879
0.5	.1915	.1950	.1985	.2019	.2054	.2088	.2123	.2157	.2190	.2224
0.6	.2257	.2291	.2324	.2357	.2389	.2422	.2454	.2486	.2517	.2549
0.7	.2580	.2611	.2642	.2673	.2703	.2734	.2764	.2794	.2823	.2852
0.8	.2881	.2910	.2939	.2967	.2995	.3023	.3051	.3078	.3106	.3133
0.9	.3159	.3186	.3213	.3238	.3264	.3289	.3315	.3340	.3365	.3389
1.0	.3413	.3438	.3461	.3485	.3508	.3531	.3554	.3577	.3599	.3621
1.1	.3643	.3665	.3686	.3708	.3729	.3749	.3770	.3790	.3910	.3830
1.2	.3849	.3869	.3888	.3907	.3925	.3944	.3962	.3980	.3997	.4015
1.3	.4032	.4049	.4066	.4082	.4099	.4115	.4131	.4147	.4162	.4177
1.4	.4192	.4207	.4222	.4236	.4251	.4265	.4279	.4292	.4306	.4319
1.5	.4332	.4345	.4357	.4370	.4382	.4394	.4406	.4418	.4429	.4441
1.6	.4452	.4463	.4474	.4484	.4495	.4505	.4515	.4525	.4535	.4545
1.7	.4554	.4564	.4573	.4582	.4591	.4599	.4608	.4616	.4625	.4633
1.8	.4641	.4649	.4656	.4664	.4671	.4678	.4686	.4693	.4699	.4706
1.9	.4713	.4719	.4726	.4732	.4738	.4744	.4750	.4756	.4761	.4767
2.0	.4772	.4778	.4783	.4788	.4793	.4798	.4803	.4808	.4812	.4817
2.1	.4821	.4829	.4830	.4834	.4838	.4842	.4846	.4850	.4854	.4857
2.2	.4861	.4864	.4868	.4871	.4875	.4878	.4881	.4884	.4887	.4890
2.3	.4893	.4896	.4898	.4901	.4904	.4906	.4909	.4911	.4913	.4916
2.4	.4918	.4920	.4922	.4925	.4927	.4929	.4931	.4932	.4934	.4936
2.5	.4938	.4940	.4941	.4943	.4945	.4946	.4948	.4949	.4951	.4952
2.6	.4953	.4955	.4956	.4957	.4959	.4960	.4961	.4962	.4963	.4964
2.7	.4965	.4966	.4967	.4968	.4969	.4970	.4971	.4972	.4973	.4974
2.8	.4974	.4975	.4976	.4977	.4977	.4978	.4979	.4979	.4980	.4981
2.9	.4981	.4982	.4982	.4983	.4984	.4984	.4985	.4985	.4986	.4986
3.0	.4987	.4987	.4987	.4988	.4988	.4989	.4989	.4989	.4990	.4990



جدول 2: توزيع Student's t

P v	.10	.05	.025	.01	.005
1	3.078	6.314	12.706	31.821	63.657
2	1.886	2.920	4.303	6.965	9.925
3	1.638	2.353	3.182	4.541	5.841
4	1.533	2.132	2.776	3.747	4.604
5	1.476	2.015	2.571	3.365	4.032
6	1.440	1.943	2.447	3.143	3.707
7	1.415	1.895	2.365	2.998	3.499
8	1.397	1.860	2.306	2.896	3.355
9	1.383	1.833	2.262	2.821	3.250
10	1.372	1.812	2.228	2.764	3.169
11	1.363	1.796	2.201	2.718	3.106
12	1.356	1.782	2.179	2.681	3.055
13	1.350	1.771	2.160	2.650	3.012
14	1.345	1.761	2.145	2.624	2.977
15	1.341	1.753	2.131	2.602	2.947
16	1.337	1.746	2.120	2.583	2.921
17	1.333	1.740	2.110	2.567	2.898
18	1.330	1.734	2.101	2.552	2.878
19	1.328	1.729	2.093	2.539	2.861
20	1.325	1.725	2.086	2.528	2.845
21	1.323	1.721	2.080	2.518	2.831
22	1.321	1.717	2.074	2.508	2.819
23	1.319	1.714	2.069	2.500	2.807
24	1.318	1.711	2.064	2.492	2.797
25	1.316	1.708	2.060	2.485	2.787
26	1.315	1.706	2.056	2.479	2.779
27	1.314	1.703	2.052	2.473	2.771
28	1.313	1.701	2.048	2.467	2.763
29	1.311	1.699	2.045	2.462	2.756
30	1.310	1.697	2.042	2.457	2.750
40	1.303	1.684	2.021	2.423	2.704
60	1.296	1.671	2.000	2.390	2.660
120	1.289	1.658	1.980	2.358	2.617
	1.282	1.645	1.960	2.326	2.576



جدول 3: توزيع Chi2

D F	p=0.99	0.98	0.95	0.90	0.80	0.70	0.50	0.30	0.20	0.10	0.05	0.02	0.01
1	0.000157	0.000628	0.00393	0.0158	0.0642	0.1488	0.455	1.074	1.642	2.706	3.841	5.412	6.635
2	0.0201	0.0404	0.103	0.211	0.446	0.713	1.386	2.408	3.219	4.605	5.991	7.824	9.210
3	0.115	0.185	0.352	0.584	1.005	1.424	2.366	3.665	4.642	6.251	7.815	9.837	11.341
4	0.297	0.429	0.711	1.064	1.649	2.195	3.357	4.878	5.989	7.779	9.488	11.668	13.277
5	0.554	0.752	1.145	1.610	2.343	3.000	4.351	6.064	7.289	9.236	11.070	13.388	15.086
6	0.872	1.134	1.635	2.204	3.070	3.828	5.348	7.231	8.558	10.645	12.592	15.033	16.812
7	1.239	1.564	2.167	2.833	3.822	4.671	6.346	8.383	9.803	12.017	14.067	16.622	18.475
8	1.646	2.032	2.733	3.490	4.594	5.527	7.344	9.524	11.030	13.362	15.507	18.168	20.090
9	2.088	2.532	3.325	4.168	5.380	6.393	8.343	10.656	12.242	14.684	16.919	19.679	21.666
10	2.558	3.059	3.940	4.865	6.179	7.267	9.342	11.781	13.442	15.987	18.307	21.161	23.209
11	3.053	3.609	4.575	5.578	6.989	8.148	10.341	12.899	14.631	17.275	19.675	22.618	24.725
12	3.571	4.178	5.226	6.304	7.807	9.034	11.340	14.011	15.812	18.549	21.026	24.054	26.217
13	4.107	4.765	5.892	7.042	8.634	9.926	12.340	15.119	16.985	19.812	22.362	25.472	27.688
14	4.660	5.368	6.571	7.790	9.467	10.821	13.339	16.222	18.151	21.064	23.685	26.873	29.141
15	5.229	5.985	7.261	8.547	10.307	11.721	14.339	17.322	19.311	22.307	24.996	28.259	30.578
16	5.812	6.614	7.962	9.312	11.152	12.624	15.338	18.418	20.465	23.542	26.296	29.633	32.000
17	6.408	7.255	8.672	10.085	12.002	13.531	16.338	19.511	21.615	24.769	27.587	30.995	33.409
18	7.015	7.906	9.390	10.865	12.857	14.440	17.338	20.601	22.760	25.989	28.869	32.346	34.805
19	7.633	8.567	10.117	11.651	13.716	15.352	18.338	21.689	23.900	27.204	30.144	33.687	36.191
20	8.260	9.237	10.851	12.443	14.578	16.266	19.337	22.775	25.038	28.412	31.410	35.020	37.566
21	8.897	9.915	11.591	13.240	15.445	17.182	20.337	23.858	26.171	29.615	32.671	36.343	38.932
22	9.542	10.600	12.338	14.041	16.314	18.101	21.337	24.939	27.301	30.813	33.924	37.659	40.289
23	10.196	11.293	13.091	14.848	17.187	19.021	22.337	26.018	28.429	32.007	35.172	38.968	41.638
24	10.856	11.992	13.848	15.659	18.062	19.943	23.337	27.096	29.553	33.196	36.415	40.270	42.980
25	11.524	12.697	14.611	16.473	18.940	20.867	24.337	28.172	30.675	34.382	37.652	41.566	44.314



جدول 3 تابع : توزيع Chi2

D	F	p=0.99	0.98	0.95	0.90	0.80	0.70	0.50	0.30	0.20	0.10	0.05	0.02	0.01
26		12.198	13.409	15.379	17.292	19.820	21.792	25.336	29.246	31.795	35.563	38.885	42.856	45.642
27		12.879	14.125	16.151	18.114	20.703	22.719	26.336	30.319	32.912	36.741	40.113	44.140	46.963
28		13.565	14.847	16.928	18.939	21.588	23.647	27.336	31.391	34.027	37.916	41.337	45.419	48.278
29		14.256	15.574	17.708	19.768	22.475	24.577	28.336	32.461	35.139	39.087	42.557	46.693	49.588
30		14.953	16.306	18.493	20.599	23.364	25.508	29.336	33.530	36.250	40.256	43.773	47.962	50.892

## جدول 4: توزيع F

درجات حرية		درجات حرية البسط											
المقام	1	2	3	4	5	6	7	8	9	10	11	12	
1	5%	161	200	216	225	230	234	237	239	241	242	243	244
	1%	4052	4999	5403	5625	5764	5859	5928	5981	6022	6056	6082	6106
2	5%	18.51	19.00	19.16	19.25	19.30	19.33	19.36	19.37	19.38	19.39	19.40	19.41
	1%	98.49	99.01	99.17	99.25	99.30	99.33	99.34	99.36	99.38	99.40	99.41	99.42
3	5%	10.13	9.55	9.28	9.12	9.01	8.94	8.88	8.84	8.81	8.78	8.76	8.74
	1%	34.12	30.81	29.46	28.71	28.24	27.91	27.67	27.49	27.34	27.23	27.13	27.05
4	5%	7.71	6.94	6.59	6.39	6.26	6.16	6.09	6.04	6.00	5.96	5.93	5.91
	1%	21.30	18.00	16.69	15.98	15.52	15.21	14.98	14.80	14.66	14.54	14.47	14.37
5	5%	6.61	5.79	5.41	5.19	5.05	4.95	4.88	4.82	4.78	4.75	4.70	4.68
	1%	16.26	13.27	12.06	11.39	10.97	10.67	10.45	10.27	10.15	10.05	9.96	9.89
6	5%	5.99	5.14	4.76	4.53	4.39	4.28	4.21	4.15	4.10	4.06	4.03	4.00
	1%	13.74	10.92	9.78	9.15	8.75	8.47	8.26	8.10	7.98	7.87	7.79	7.72
7	5%	5.59	4.74	4.35	4.12	3.97	3.87	3.79	3.73	3.68	3.63	3.60	3.57
	1%	12.25	9.55	8.45	7.85	7.46	7.19	7.00	6.84	6.71	6.62	6.54	6.47
8	5%	5.32	4.46	4.07	3.84	3.69	3.58	3.50	3.44	3.39	3.34	3.31	3.28
	1%	11.26	8.65	7.59	7.01	6.63	6.37	6.19	6.03	5.91	5.82	5.74	5.67
9	5%	5.12	4.26	3.86	3.63	3.48	3.37	3.29	3.23	3.18	3.13	3.10	3.07
	1%	10.56	8.02	6.99	6.42	6.06	5.80	5.62	5.47	5.35	5.26	5.18	5.11
10	5%	4.96	4.10	3.71	3.48	3.33	3.22	3.14	3.07	3.02	2.97	2.94	2.91
	1%	10.04	7.56	6.55	5.99	5.64	5.39	5.21	5.06	4.95	4.85	4.78	4.71
11	5%	4.84	3.98	3.59	3.36	3.20	3.09	3.01	2.95	2.90	2.96	2.82	2.79
	1%	9.65	7.20	6.22	5.67	5.32	5.07	4.88	4.74	4.63	4.54	4.46	4.40
12	5%	4.75	3.88	3.49	3.26	3.11	3.00	2.92	2.85	2.80	2.76	2.72	2.69
	1%	9.33	6.93	5.95	5.41	5.06	4.82	4.65	4.50	4.39	4.30	4.22	4.16
13	5%	4.67	3.80	3.41	3.18	3.02	2.92	2.84	2.77	2.72	2.67	2.63	2.60
	1%	9.07	6.70	5.74	5.20	4.86	4.62	4.44	4.30	4.19	4.10	4.02	3.96



## جدول 4 تابع : توزيع F

درجات حرية المقام	درجات حرية البسط											
	1	2	3	4	5	6	7	8	9	10	11	12
14 5%	4.60	3.74	3.34	3.11	2.96	2.85	2.77	2.70	2.65	2.60	2.56	2.53
14 1%	8.86	6.51	5.56	5.03	4.69	4.46	4.28	4.14	4.03	3.94	3.86	3.80
15 5%	4.54	3.68	3.29	3.06	2.90	2.79	2.70	2.64	2.59	2.55	2.51	2.48
15 1%	8.68	6.36	5.42	4.89	4.56	4.32	4.14	4.00	3.89	3.80	3.73	3.67
16 5%	4.49	3.63	3.24	3.01	2.85	2.74	2.66	2.59	2.54	2.49	2.45	2.42
16 1%	8.53	6.23	5.29	4.77	4.44	4.20	4.03	3.89	3.78	3.69	3.61	3.55
17 5%	4.45	3.59	3.20	2.96	2.81	2.70	2.62	2.55	2.50	2.45	2.41	2.38
17 1%	8.40	6.11	5.18	4.67	4.34	4.10	3.93	3.79	3.68	3.59	3.52	3.45
18 5%	4.41	3.55	3.16	2.93	2.77	2.66	2.58	2.51	2.46	2.41	2.37	2.34
18 1%	8.28	6.01	5.09	4.58	4.25	4.01	3.85	3.71	3.60	3.51	3.44	3.37
19 5%	4.38	3.52	3.13	2.90	2.74	2.63	2.55	2.48	2.43	2.38	2.34	2.31
19 1%	8.18	3.93	5.01	4.50	4.17	3.94	3.77	3.63	3.52	3.43	3.36	3.30
20 5%	4.35	3.49	3.10	2.87	2.71	2.60	2.52	2.45	2.40	2.35	2.31	2.28
20 1%	8.10	5.85	4.94	4.43	4.10	3.87	3.71	3.56	3.45	3.37	3.30	3.23
21 5%	4.32	3.47	3.07	2.84	2.68	2.57	2.49	2.42	2.37	2.32	2.28	2.25
21 1%	8.02	5.78	4.87	4.37	4.04	3.81	3.65	3.51	3.40	3.31	3.24	3.17
22 5%	4.30	3.44	3.05	2.82	2.66	2.55	2.47	2.40	2.35	2.30	2.26	2.32
22 1%	7.94	5.72	4.82	4.31	3.99	3.76	3.59	3.45	3.35	3.26	3.18	3.12
23 5%	4.28	3.42	3.03	2.80	2.64	2.53	2.45	2.38	2.32	2.28	2.24	2.20
23 1%	7.88	5.66	4.76	4.26	3.94	3.71	3.54	3.41	3.30	3.21	3.14	3.07
24 5%	4.26	3.40	3.01	2.78	2.62	2.51	2.43	2.36	2.30	2.26	2.22	2.18
24 1%	7.82	5.61	4.72	4.22	3.90	3.67	3.50	3.36	3.25	3.17	3.09	3.03
25 5%	4.24	3.38	2.99	2.76	2.60	2.49	2.41	2.34	2.28	2.24	2.20	2.16
25 1%	7.77	5.57	4.68	4.18	3.86	3.63	3.46	3.32	3.21	3.13	3.05	2.99
26 5%	4.22	3.37	2.89	2.74	2.59	2.47	2.39	2.32	2.27	2.22	2.18	2.15
26 1%	7.72	5.53	4.64	4.14	3.82	3.59	3.42	3.29	3.17	3.09	3.02	2.96



جدول 4 تابع : توزيع F

درجات حرية المقام	درجات حرية البسط											
	1	2	3	4	5	6	7	8	9	10	11	12
27	5% 4.21	3.35	2.96	2.73	2.57	2.46	2.37	2.30	2.25	2.20	2.16	2.13
	1% 7.68	5.49	4.60	4.11	3.79	3.56	3.39	3.26	3.14	3.06	2.98	2.93
28	5% 4.20	3.34	2.95	2.71	2.56	2.44	2.36	2.29	3.24	2.19	2.15	2.12
	1% 7.64	5.45	4.57	4.07	3.76	3.53	3.36	3.23	3.11	3.03	2.95	2.90
29	5% 4.18	3.33	2.93	2.70	2.54	2.43	2.35	2.28	2.22	2.18	2.14	2.10
	1% 7.60	5.52	4.54	4.04	3.73	3.50	3.33	3.20	3.08	3.00	2.92	2.87
30	5% 4.17	3.32	2.92	2.69	2.53	2.42	2.34	2.27	2.21	2.16	2.12	2.09
	1% 7.56	5.39	4.51	4.02	3.70	3.47	3.30	3.17	3.06	2.98	2.90	2.84
32	5% 4.15	3.30	2.90	2.67	2.51	2.40	2.32	2.25	2.19	2.14	2.10	2.07
	1% 7.50	5.34	4.46	3.97	3.66	3.42	3.25	3.12	3.01	2.94	2.86	2.80
34	5% 4.13	3.28	2.88	2.65	2.49	2.38	2.30	2.23	2.17	2.12	2.08	2.05
	1% 7.44	5.29	4.42	3.93	3.61	3.38	3.21	3.08	2.97	2.89	2.82	2.76
36	5% 4.11	3.26	2.86	2.63	2.48	2.36	2.28	2.21	2.15	2.10	2.06	2.03
	1% 7.39	5.25	4.38	3.89	3.58	3.35	3.18	3.04	2.94	2.86	2.78	2.72
38	5% 4.10	3.25	2.85	2.62	2.46	2.35	2.26	2.19	2.14	2.09	2.05	2.02
	1% 7.35	5.21	4.34	3.86	3.54	3.32	3.15	3.02	2.91	2.82	2.75	2.69
40	5% 4.08	3.23	2.84	2.61	2.45	2.34	2.25	2.18	2.12	2.07	2.04	2.00
	1% 7.31	5.18	4.31	3.83	3.51	3.29	3.12	2.99	2.88	2.80	2.73	2.66
42	5% 4.07	3.22	2.83	2.59	2.44	2.32	2.24	2.17	2.11	2.06	2.02	1.99
	1% 7.27	5.15	4.29	3.80	3.49	3.26	3.10	2.96	2.86	2.77	2.70	2.64
44	5% 4.06	3.21	2.82	2.58	2.43	2.31	2.23	2.16	2.10	2.05	2.01	1.98
	1% 7.24	5.12	4.26	3.78	3.46	3.24	3.07	2.94	2.84	2.75	2.68	2.62
46	5% 4.05	3.20	2.81	2.57	2.42	2.30	2.22	2.14	2.09	2.04	2.00	1.97
	1% 7.21	5.10	4.24	3.76	3.44	3.22	3.05	2.92	2.82	2.73	2.66	2.60
48	5% 4.04	3.19	2.80	2.56	2.41	2.30	2.21	2.14	2.08	2.03	1.99	1.96
	1% 7.19	5.08	4.22	3.74	3.42	3.20	3.04	2.90	2.80	2.71	2.64	2.58



جدول 4 تابع : توزيع F

درجات حرية المقام	درجات حرية البسط											
	1	2	3	4	5	6	7	8	9	10	11	12
50	5% 4.03	3.18	2.79	2.56	2.40	2.29	2.20	2.13	2.07	2.02	1.98	1.95
	1% 7.17	5.06	4.20	3.72	3.41	3.18	3.02	2.88	2.78	2.70	2.62	2.56
55	5% 4.02	3.17	2.78	2.54	2.38	2.27	2.18	2.11	2.05	2.00	1.97	1.93
	1% 7.12	5.01	4.16	3.68	3.37	3.15	2.98	2.85	2.75	2.66	2.59	2.53
60	5% 4.00	3.15	2.76	2.52	2.37	2.25	2.17	2.10	2.04	1.99	1.95	1.92
	1% 7.08	4.98	4.13	3.65	3.34	3.12	2.95	2.82	2.72	2.63	2.56	2.50
65	5% 3.99	3.14	2.75	2.51	2.36	2.24	2.15	2.08	2.02	1.98	1.94	1.90
	1% 7.04	4.95	4.10	3.62	3.31	3.09	2.93	2.79	2.70	2.62	2.54	2.47
70	5% 3.98	3.13	2.74	2.50	2.35	2.32	2.14	2.07	2.01	1.97	1.93	1.89
	1% 7.01	4.92	4.08	3.60	3.29	3.07	2.91	2.77	2.67	2.59	2.51	2.45
80	5% 3.96	3.11	2.72	2.48	2.33	2.21	2.12	2.05	1.99	1.95	1.91	1.88
	1% 6.96	4.88	4.04	3.56	3.25	3.04	2.87	2.74	2.64	2.55	2.48	2.41
100	5% 3.94	3.09	2.70	2.46	2.30	2.19	2.10	2.03	1.97	1.92	1.88	1.85
	1% 6.90	4.82	3.98	3.51	3.20	2.99	2.82	2.69	2.59	2.51	2.43	2.36
125	5% 3.92	3.07	2.68	2.44	2.29	2.17	2.08	2.01	1.95	1.90	1.86	1.83
	1% 6.84	4.78	3.94	3.47	3.17	2.95	2.79	2.65	2.56	2.47	2.40	2.33
150	5% 3.91	3.06	2.67	2.43	2.27	2.16	2.07	2.00	1.94	1.89	1.85	1.82
	1% 6.81	4.75	3.91	3.44	3.13	2.92	2.76	2.62	2.53	2.44	2.37	2.30
200	5% 3.89	3.04	2.65	2.41	2.26	2.14	2.05	1.98	1.92	1.87	1.83	1.80
	1% 6.76	4.71	3.88	3.41	3.11	2.90	2.73	2.60	2.50	2.41	2.34	2.28
400	5% 3.86	3.02	2.62	2.39	2.23	2.12	2.03	1.96	1.90	1.85	1.81	1.78
	1% 6.70	4.66	3.83	3.36	3.06	2.85	2.69	2.55	2.49	2.37	2.29	2.23
1000	5% 3.85	3.00	2.61	2.38	2.22	2.10	2.02	1.95	1.89	1.84	1.80	1.76
	1% 6.66	4.62	3.80	3.34	3.04	2.82	2.66	2.53	2.43	2.34	2.26	2.20
∞	5% 3.84	2.99	2.60	2.37	2.21	2.09	2.01	1.94	1.88	1.83	1.79	1.75
	1% 6.64	4.60	3.78	3.32	3.02	2.80	2.64	2.51	2.41	2.32	2.24	2.18



جدول 4 تابع : توزيع F

درجات حرية		درجات حرية البسط											
المقام		14	16	20	24	30	40	50	75	100	200	500	$\infty$
1	5%	245	246	248	249	250	251	252	253	253	254	254	254
	1%	6142	6169	6208	6234	6258	6286	6302	6323	6334	6352	6361	6366
2	5%	19.42	19.43	19.44	19.45	19.46	19.47	19.47	19.48	19.49	19.49	19.50	19.50
	1%	99.43	99.44	99.45	99.46	99.47	99.48	99.48	99.49	99.49	99.49	99.50	99.50
3	5%	8.71	8.69	8.66	8.64	8.62	8.60	8.58	8.57	8.56	8.54	8.54	8.53
	1%	26.92	26.83	26.69	26.60	26.50	26.41	26.30	26.27	26.23	26.18	26.14	26.12
4	5%	5.87	5.84	5.80	5.77	5.74	5.71	5.70	5.68	5.66	5.65	5.64	5.63
	1%	14.24	14.15	14.02	13.93	13.83	13.74	13.69	13.61	13.57	13.52	13.48	13.46
5	5%	4.64	4.60	4.56	4.53	4.50	4.46	4.44	4.42	4.40	4.38	4.37	4.36
	1%	9.77	9.68	9.55	9.47	9.38	9.29	9.24	9.17	9.13	9.07	9.04	9.02
6	5%	3.96	3.92	3.87	3.84	3.81	3.77	3.75	3.72	3.71	3.69	3.68	3.67
	1%	7.60	7.52	7.39	7.31	7.23	7.14	7.09	7.02	6.99	6.94	6.90	6.88
7	5%	3.52	3.49	3.44	3.41	3.38	3.34	3.32	3.29	3.28	3.25	3.24	3.23
	1%	6.35	6.27	6.15	6.07	5.98	5.90	5.85	5.78	5.75	5.70	5.67	5.65
8	5%	3.23	3.20	3.15	3.12	3.08	3.05	3.03	3.00	2.98	2.96	2.94	2.93
	1%	5.56	5.48	5.36	5.28	5.20	5.11	5.06	5.00	4.96	4.91	4.88	4.86
9	5%	3.02	2.98	2.93	2.90	2.86	2.82	2.80	2.77	2.76	2.73	2.72	2.71
	1%	5.00	4.92	4.80	4.73	4.64	4.56	4.51	4.45	4.41	4.36	4.33	4.31
10	5%	2.86	2.82	2.77	2.74	2.70	2.67	2.64	2.61	2.59	2.56	2.55	2.54
	1%	4.60	4.52	4.41	4.33	4.25	4.17	4.12	4.05	4.01	3.96	3.93	3.91
11	5%	2.74	2.70	2.65	2.61	2.57	2.53	2.50	2.47	2.45	2.42	2.41	2.40
	1%	4.29	4.21	4.10	4.02	3.94	3.86	3.80	3.74	3.70	3.66	3.62	3.60
12	5%	2.64	2.60	2.54	2.50	2.46	2.42	2.40	2.36	2.35	2.32	2.31	2.30
	1%	4.05	3.98	3.86	3.78	3.70	3.61	3.56	3.49	3.46	3.41	3.38	3.36
13	5%	2.55	2.51	2.46	2.42	2.38	2.34	2.32	2.28	2.26	2.24	2.22	2.21
	1%	3.85	3.78	3.67	3.59	3.51	3.42	3.37	3.30	3.27	3.21	3.18	3.16



جدول 4 تابع : توزيع F

درجات حرية المقام		درجات حرية البسط											∞
		14	16	20	24	30	40	50	75	100	200	500	
14	5%	2.48	2.44	2.39	2.35	2.31	2.27	2.24	2.21	2.19	2.16	2.14	2.13
	1%	3.70	3.62	3.51	3.43	3.34	3.26	3.21	3.14	3.11	3.06	3.02	3.00
15	5%	2.43	2.39	2.33	2.29	2.25	2.21	2.18	2.15	2.12	2.10	2.08	2.07
	1%	3.56	3.48	3.36	3.29	3.20	3.12	3.07	3.00	2.97	2.92	2.89	2.87
16	5%	2.37	2.33	2.28	2.24	2.20	2.16	2.13	2.09	2.07	2.04	2.02	2.01
	1%	3.45	3.37	3.25	3.18	3.10	3.01	2.96	2.89	2.86	2.80	2.77	2.75
17	5%	2.33	2.29	2.23	2.19	2.15	2.11	2.08	2.04	2.02	1.99	1.97	1.96
	1%	3.35	3.27	3.16	3.08	3.00	2.92	2.86	2.79	2.76	2.70	2.67	2.65
18	5%	2.29	2.25	2.19	2.15	2.11	2.07	2.04	2.00	1.98	1.95	1.93	1.92
	1%	3.27	3.19	3.07	3.00	2.91	2.83	2.78	2.71	2.68	2.62	2.59	2.57
19	5%	2.26	2.21	2.15	2.11	2.07	2.02	2.00	1.96	1.94	1.91	1.90	1.88
	1%	3.19	3.12	3.00	2.92	2.84	2.76	2.70	2.63	2.60	2.54	2.51	2.49
20	5%	2.23	2.18	2.12	2.08	2.04	1.99	1.96	1.92	1.90	1.87	1.85	1.84
	1%	3.13	3.05	2.94	2.86	2.77	2.69	2.63	2.56	2.53	2.47	2.44	2.42
21	5%	2.20	2.15	2.09	2.05	2.00	1.96	1.93	1.89	1.87	1.84	1.82	1.81
	1%	3.07	2.99	2.88	2.80	2.72	2.63	2.58	2.51	2.47	2.42	2.38	2.36
22	5%	2.18	2.13	2.07	2.03	1.98	1.93	1.91	1.87	1.84	1.81	1.80	1.78
	1%	3.02	2.94	2.83	2.75	2.67	2.58	2.53	2.46	2.42	2.37	2.33	2.31
23	5%	2.14	2.10	2.04	2.00	1.96	1.91	1.88	1.84	1.82	1.79	1.77	1.76
	1%	2.97	2.89	2.78	2.70	2.62	2.53	2.48	2.41	2.37	2.32	2.28	2.26
24	5%	2.13	2.09	2.02	1.98	1.94	1.89	1.86	1.82	1.80	1.76	1.74	1.73
	1%	2.93	2.85	2.74	2.66	2.58	2.49	2.44	2.36	2.33	2.27	2.23	2.21
25	5%	2.11	2.06	2.00	1.96	1.92	1.87	1.84	1.80	1.77	1.74	1.72	1.71
	1%	2.89	2.81	2.70	2.62	2.54	2.45	2.40	2.32	2.29	2.23	2.19	2.17
26	5%	2.10	2.05	1.99	1.95	1.90	1.85	1.82	1.78	1.76	1.72	1.70	1.96
	1%	2.86	2.77	2.66	2.58	2.50	2.41	2.36	2.28	2.25	2.19	2.15	2.13



جدول 4 تابع : توزيع F

درجات حرية		درجات حرية البسط											
		المقام	14	16	20	24	30	40	50	75	100	200	500
27	5%	2.08	2.03	1.97	1.93	1.88	1.84	1.80	1.76	1.74	1.71	1.68	1.67
	1%	2.83	2.74	2.63	2.55	2.47	2.38	2.33	2.25	2.21	2.16	2.12	2.10
28	5%	2.06	2.02	1.96	1.91	1.87	1.81	1.78	1.75	1.72	1.69	1.67	1.65
	1%	2.80	2.71	2.60	2.52	2.44	2.35	2.30	2.22	2.18	2.13	2.09	2.06
29	5%	2.05	2.00	1.94	1.90	1.85	1.80	1.77	1.73	1.71	1.68	1.65	1.64
	1%	2.77	2.68	2.57	2.49	2.41	2.32	2.27	2.19	2.15	2.10	2.06	2.03
30	5%	2.04	1.99	1.93	1.89	1.84	1.79	1.76	1.72	1.69	1.66	1.64	1.62
	1%	2.74	2.66	2.55	2.47	2.38	2.29	2.24	2.16	2.13	2.07	2.03	2.01
32	5%	2.02	1.97	1.91	1.86	1.82	1.76	1.74	1.69	1.67	1.64	1.61	1.59
	1%	2.70	2.62	2.51	2.42	2.34	2.25	2.20	2.12	2.08	2.02	1.98	1.96
34	5%	2.00	1.95	1.89	1.84	1.80	1.74	1.71	1.67	1.64	1.61	1.59	1.57
	1%	2.66	2.58	2.47	2.38	2.30	2.21	2.15	2.08	2.04	1.98	1.94	1.91
36	5%	1.89	1.93	1.87	1.82	1.78	1.72	1.69	1.65	1.62	1.59	1.56	1.55
	1%	2.62	2.54	2.43	2.35	2.26	2.17	2.12	2.04	2.00	1.94	1.90	1.87
38	5%	1.96	1.92	1.85	1.80	1.76	1.71	1.67	1.63	1.60	1.57	1.54	1.53
	1%	2.59	2.51	2.30	2.32	2.22	2.14	2.08	2.00	1.97	1.90	1.86	1.84
40	5%	1.95	1.90	1.84	1.79	1.74	1.69	1.66	1.61	1.59	1.55	1.53	1.51
	1%	2.56	2.49	2.37	2.29	2.20	2.11	2.05	1.97	1.94	1.88	1.84	1.81
42	5%	1.94	1.89	1.82	1.78	1.73	1.68	1.64	1.60	1.57	1.54	1.51	1.49
	1%	2.54	2.46	2.35	2.26	2.17	2.08	2.02	1.94	1.91	1.85	1.80	1.78
44	5%	1.92	1.88	1.81	1.76	1.72	1.66	1.63	1.58	1.56	1.52	1.50	1.48
	1%	2.52	2.44	2.32	2.24	2.15	2.06	2.00	1.92	1.88	1.82	1.78	1.75
46	5%	1.91	1.87	1.80	1.75	1.71	1.65	1.62	1.57	1.54	1.51	1.48	1.46
	1%	2.50	2.42	2.40	2.22	2.13	2.04	1.98	1.90	1.86	1.80	1.76	1.72
48	5%	1.90	1.86	1.79	1.74	1.70	1.64	1.61	1.56	1.53	1.50	1.47	1.45
	1%	2.48	2.40	2.28	2.20	2.11	2.02	1.96	1.88	1.84	1.78	1.73	1.70



جدول 4 تابع : توزيع F

درجات حرية المقام		درجات حرية البسط											
		14	16	20	24	30	40	50	75	100	200	500	∞
50	5%	1.90	1.85	1.78	1.74	1.69	1.63	1.60	1.55	1.52	1.48	1.46	1.44
	1%	2.46	2.39	2.26	2.18	2.10	2.00	1.94	1.86	1.82	1.76	1.71	1.68
55	5%	1.88	1.83	1.76	1.72	1.67	1.61	1.58	1.52	1.50	1.46	1.43	1.41
	1%	2.43	2.35	2.23	2.15	2.06	1.96	1.90	1.82	1.78	1.71	1.66	1.64
60	5%	1.86	1.81	1.75	1.70	1.65	1.59	1.56	1.50	1.48	1.44	1.41	1.39
	1%	2.40	2.32	2.20	2.12	2.03	1.93	1.87	1.79	1.74	1.68	1.63	1.60
65	5%	1.85	1.80	1.73	1.68	1.63	1.57	1.54	1.49	1.46	1.42	1.39	1.37
	1%	2.30	2.37	2.18	2.09	2.00	1.90	1.84	1.76	1.71	1.64	1.60	1.56
70	5%	1.84	1.79	1.72	1.67	1.62	1.56	1.53	1.47	1.45	1.40	1.37	1.35
	1%	2.35	2.28	2.15	2.07	1.98	1.88	1.82	1.74	1.69	1.63	1.56	1.53
80	5%	1.82	1.77	1.70	1.65	1.60	1.54	1.51	1.45	1.42	1.38	1.35	1.32
	1%	2.32	2.24	2.11	2.03	1.94	1.84	1.78	1.70	1.65	1.57	1.52	1.49
100	5%	1.79	1.75	1.68	1.63	1.57	1.51	1.48	1.42	1.39	1.34	1.30	1.28
	1%	2.26	2.19	2.06	1.98	1.89	1.79	1.73	1.64	1.59	1.51	1.46	1.43
125	5%	1.77	1.72	1.65	1.60	1.55	1.49	1.45	1.39	1.36	1.31	1.27	1.25
	1%	2.23	2.15	2.03	1.94	1.85	1.75	1.68	1.59	1.54	1.46	1.40	1.37
150	5%	1.76	1.71	1.64	1.59	1.54	1.47	1.44	1.37	1.34	1.29	1.25	1.22
	1%	2.20	2.12	2.00	1.91	1.83	1.72	1.66	1.56	1.51	1.43	1.37	1.33
200	5%	1.74	1.69	1.62	1.57	1.52	1.45	1.42	1.35	1.32	1.26	1.22	1.19
	1%	1.17	2.09	1.97	1.88	1.79	1.69	1.62	1.53	1.48	1.39	1.33	1.28
400	5%	1.72	1.67	1.60	1.54	1.49	1.42	1.38	1.32	1.28	1.22	1.16	1.13
	1%	2.12	2.04	1.92	1.84	1.74	1.64	1.57	1.47	1.42	1.32	1.24	1.19
1000	5%	1.70	1.65	1.58	1.53	1.47	1.41	1.36	1.30	1.26	1.19	1.13	1.08
	1%	2.09	2.01	1.89	1.81	1.71	1.61	1.54	1.44	1.38	1.28	1.19	1.11
∞	5%	1.69	1.64	1.57	1.52	1.46	1.40	1.35	1.28	1.24	1.17	1.11	1.00
	1%	2.07	1.99	1.87	1.79	1.69	1.59	1.52	1.41	1.36	1.25	1.15	1.00



الجدول 5: إحصاءة داربين-واتسون بمستوى معنوية 1 %

n	k'=1		k'=2		k'=3		k'=4		k'=5	
	dL	dU	dL	dU	dL	dU	dL	dU	dL	dU
6	0.390	1.142	---	---	---	---	---	---	---	---
7	0.435	1.036	0.294	1.676	---	---	---	---	---	---
8	0.497	1.003	0.345	1.489	0.229	2.102	---	---	---	---
9	0.554	0.998	0.408	1.389	0.279	1.875	0.183	2.433	---	---
10	0.604	1.001	0.466	1.333	0.340	1.733	0.230	2.193	0.150	2.690
11	0.653	1.010	0.519	1.297	0.396	1.640	2.286	2.030	0.193	2.453
12	0.697	1.023	0.569	1.274	0.449	1.575	0.339	1.913	0.244	2.280
13	0.738	1.038	0.616	1.261	0.499	1.526	0.391	1.826	0.294	2.150
14	0.776	1.054	0.660	1.254	0.547	1.490	0.441	1.757	0.343	2.049
15	0.811	1.070	0.700	1.252	0.591	1.464	0.488	1.704	0.391	1.967
16	0.844	1.086	0.737	1.252	0.633	1.446	0.532	1.663	0.437	1.900
17	0.874	1.102	0.772	1.255	0.672	1.432	0.574	1.630	0.480	1.847
18	0.902	1.118	0.805	1.259	0.708	1.422	0.613	1.604	0.522	1.803
19	0.928	1.132	0.835	1.265	0.742	1.415	0.650	1.584	0.561	1.767
20	0.952	1.147	0.863	1.271	0.773	1.411	0.685	1.567	0.598	1.737
21	0.975	1.161	0.890	1.277	0.803	1.408	0.718	1.554	0.633	1.712
22	0.997	1.174	0.914	1.284	0.831	1.407	0.748	1.543	0.667	1.691
23	1.018	1.187	0.938	1.291	0.858	1.407	0.777	1.534	0.698	1.673
24	1.037	1.199	0.960	1.298	0.882	1.407	0.805	1.528	0.728	1.658
25	1.055	1.211	0.981	1.305	0.906	1.409	0.831	1.523	0.756	1.645
26	1.072	1.222	1.001	1.312	0.928	1.411	0.855	1.518	0.783	1.635
27	1.089	1.233	1.019	1.319	0.949	1.413	0.878	1.515	0.808	1.626
28	1.104	1.244	1.037	1.325	0.966	1.415	0.900	1.513	0.832	1.618
29	1.119	1.254	1.054	1.332	0.988	1.418	0.921	1.512	0.855	1.611
30	1.133	1.263	1.070	1.339	1.006	1.421	0.941	1.511	0.877	1.606
31	1.147	1.273	1.085	1.345	1.023	1.425	0.960	1.510	0.897	1.601
32	1.160	1.282	1.100	1.352	1.040	1.428	0.979	1.510	0.917	1.597
33	1.172	1.291	1.114	1.358	1.055	1.432	0.996	1.510	0.936	1.594
34	1.184	1.299	1.128	1.364	1.070	1.435	1.012	1.511	0.954	1.591
35	1.195	1.307	1.140	1.370	1.085	1.439	1.028	1.512	0.971	1.589
36	1.206	1.315	1.153	1.376	1.098	1.442	1.043	1.513	0.988	1.588
37	1.217	1.323	1.165	1.382	1.112	1.446	1.058	1.514	1.004	1.586
38	1.227	1.330	1.176	1.388	1.124	1.449	1.072	1.515	1.019	1.585
39	1.237	1.337	1.187	1.393	1.137	1.453	1.085	1.517	1.034	1.584
40	1.246	1.344	1.198	1.398	1.148	1.457	1.098	1.518	1.048	1.584
45	1.288	1.376	1.245	1.423	1.201	1.474	1.156	1.528	1.111	1.584
50	1.324	1.403	1.285	1.446	1.245	1.491	1.205	1.538	1.164	1.587
55	1.356	1.427	1.320	1.466	1.284	1.506	1.247	1.548	1.209	1.592
60	1.383	1.449	1.350	1.484	1.317	1.520	1.283	1.558	1.249	1.598
65	1.407	1.468	1.377	1.500	1.346	1.534	1.315	1.568	1.283	1.604
70	1.429	1.485	1.400	1.515	1.372	1.546	1.343	1.578	1.313	1.611
75	1.448	1.501	1.422	1.529	1.395	1.557	1.368	1.587	1.340	1.617
80	1.466	1.515	1.441	1.541	1.416	1.568	1.390	1.595	1.364	1.624
85	1.482	1.528	1.458	1.553	1.435	1.578	1.411	1.603	1.386	1.630
90	1.496	1.540	1.474	1.563	1.452	1.587	1.429	1.611	1.406	1.636
95	1.510	1.552	1.489	1.573	1.468	1.596	1.446	1.618	1.425	1.642
100	1.522	1.562	1.503	1.583	1.482	1.604	1.462	1.625	1.441	1.647
150	1.611	1.637	1.598	1.651	1.584	1.665	1.571	1.679	1.557	1.693
200	1.664	1.684	1.653	1.693	1.643	1.704	1.633	1.715	1.623	1.725



الجدول 5 تابع : إحصاءة داربين-واتسون بمستوى معنوية 1 %

n	k'=6		k'=7		k'=8		k'=9		k'=10	
	dL	dU	dL	dU	dL	dU	dL	dU	dL	dU
6	---	---	---	---	---	---	---	---	---	---
7	---	---	---	---	---	---	---	---	---	---
8	---	---	---	---	---	---	---	---	---	---
9	---	---	---	---	---	---	---	---	---	---
10	---	---	---	---	---	---	---	---	---	---
11	0.124	2.892	---	---	---	---	---	---	---	---
12	0.164	2.665	0.105	0.053	---	---	---	---	---	---
13	0.211	2.490	0.140	2.838	0.090	3.182	---	---	---	---
14	0.257	2.354	0.183	2.667	0.122	2.981	0.078	3.287	---	---
15	0.303	2.244	0.226	2.530	0.161	2.817	0.107	3.101	0.068	3.374
16	0.349	2.153	0.269	2.416	0.200	2.681	0.142	2.944	0.094	3.201
17	0.393	2.078	0.313	2.319	0.241	2.566	0.179	2.811	0.127	3.053
18	0.435	2.015	0.355	2.238	0.282	2.467	0.216	2.697	0.160	2.925
19	0.476	1.963	0.396	2.169	0.322	2.381	0.255	2.597	0.196	2.813
20	0.515	1.918	0.436	2.110	0.362	2.308	0.294	2.510	0.232	2.714
21	0.552	1.881	0.474	2.059	0.400	2.244	0.331	2.434	0.268	2.625
22	0.587	1.849	0.510	2.015	0.437	2.188	0.368	2.367	0.304	2.548
23	0.620	1.821	0.545	1.977	0.473	2.140	0.404	2.308	0.340	2.479
24	0.652	1.797	0.578	1.944	0.507	2.097	0.439	2.255	0.375	2.417
25	0.682	1.766	0.610	1.915	0.540	2.059	0.473	2.209	0.409	2.362
26	0.711	1.759	0.640	1.889	0.572	2.026	0.505	2.168	0.441	2.313
27	0.738	1.743	0.669	1.867	0.602	1.997	0.536	2.131	0.473	2.269
28	0.764	1.729	0.696	1.847	0.630	1.970	0.566	2.098	0.504	2.229
29	0.788	1.718	0.723	1.830	0.658	1.947	0.595	2.068	0.533	2.193
30	0.812	1.707	0.748	1.814	0.684	1.925	0.622	2.041	0.562	2.160
31	0.834	1.698	0.772	1.800	0.710	1.906	0.649	2.017	0.589	2.131
32	0.856	1.690	0.794	1.788	0.734	1.889	0.674	1.995	0.615	2.104
33	0.876	1.683	0.816	1.776	0.757	1.874	0.698	1.975	0.641	2.080
34	0.896	1.677	0.837	1.766	0.779	1.860	0.722	1.957	0.665	2.057
35	0.914	1.671	0.857	1.757	0.800	1.847	0.744	1.940	0.689	2.037
36	0.932	1.666	0.877	1.749	0.821	1.836	0.766	1.925	0.711	2.018
37	0.950	1.662	0.895	1.742	0.841	1.825	0.787	1.911	0.733	2.001
38	0.966	1.658	0.913	1.735	0.860	1.816	0.807	1.899	0.754	1.985
39	0.982	1.655	0.930	1.729	0.878	1.807	0.826	1.887	0.774	1.970
40	0.997	1.652	0.946	1.724	0.895	1.799	0.844	1.876	0.789	1.956
45	1.065	1.643	1.019	1.704	0.974	1.768	0.927	1.834	0.881	1.902
50	1.123	1.639	1.081	1.692	1.039	1.748	0.997	1.805	0.955	1.864
55	1.172	1.638	1.134	1.685	1.095	1.734	1.057	1.785	1.018	1.837
60	1.214	1.639	1.179	1.682	1.144	1.726	1.108	1.771	1.072	1.817
65	1.251	1.642	1.218	1.680	1.186	1.720	1.153	1.761	1.120	1.802
70	1.283	1.645	1.253	1.680	1.223	1.716	1.192	1.754	1.162	1.792
75	1.313	1.646	1.284	1.682	1.256	1.716	1.227	1.746	1.199	1.785
80	1.338	1.653	1.312	1.683	1.285	1.714	1.259	1.745	1.232	1.777
85	1.362	1.657	1.337	1.685	1.312	1.714	1.287	1.743	1.262	1.773
90	1.383	1.661	1.360	1.687	1.336	1.714	1.312	1.741	1.288	1.769
95	1.403	1.666	1.381	1.690	1.358	1.715	1.336	1.741	1.313	1.767
100	1.421	1.670	1.400	1.693	1.378	1.717	1.357	1.741	1.335	1.765
150	1.543	1.708	1.530	1.722	1.515	1.737	1.501	1.752	1.486	1.767
200	1.613	1.735	1.603	1.746	1.592	1.757	1.582	1.768	1.571	1.779



الجدول 6: إحصاءة داربين-واتسون بمستوى معنوية 5 %

n	k'=1		k'=2		k'=3		k'=4		k'=5	
	dL	dU	dL	dU	dL	dU	dL	dU	dL	dU
6	0.610	1.400	---	---	---	---	---	---	---	---
7	0.700	1.356	0.467	1.896	---	---	---	---	---	---
8	0.763	1.332	0.559	1.777	0.368	2.287	---	---	---	---
9	0.824	1.320	0.629	1.699	0.455	2.128	0.296	2.588	---	---
10	0.879	1.320	0.697	1.641	0.525	2.016	0.376	2.414	0.243	2.822
11	0.927	1.324	0.758	1.604	0.595	1.928	0.444	2.283	0.316	2.645
12	0.971	1.331	0.812	1.579	0.658	1.864	0.512	2.177	0.379	2.506
13	1.010	1.340	0.861	1.562	0.715	1.816	0.574	2.094	0.445	2.390
14	1.045	1.350	0.905	1.551	0.767	1.779	0.632	2.030	0.505	2.296
15	1.077	1.361	0.946	1.543	0.814	1.750	0.685	1.977	0.562	2.220
16	1.106	1.371	0.982	1.539	0.857	1.728	0.734	1.935	0.615	2.157
17	1.133	1.381	1.015	1.536	0.897	1.710	0.779	1.900	0.664	2.104
18	1.158	1.391	1.046	1.535	0.933	1.696	0.820	1.872	0.710	2.060
19	1.180	1.401	1.074	1.536	0.967	1.685	0.859	1.848	0.752	2.023
20	1.201	1.411	1.100	1.537	0.998	1.676	0.894	1.828	0.792	1.991
21	1.221	1.420	1.125	1.538	1.026	1.669	0.927	1.812	0.829	1.964
22	1.239	1.429	1.147	1.541	1.053	1.664	0.958	1.797	0.863	1.940
23	1.257	1.437	1.168	1.543	1.078	1.660	0.986	1.785	0.895	1.920
24	1.273	1.446	1.188	1.546	1.101	1.656	1.013	1.775	0.925	1.902
25	1.288	1.454	1.206	1.550	1.123	1.654	1.038	1.767	0.953	1.886
26	1.302	1.461	1.224	1.553	1.143	1.652	1.062	1.759	0.979	1.837
27	1.316	1.459	1.240	1.556	1.162	1.651	1.084	1.753	1.004	1.861
28	1.328	1.476	1.255	1.560	1.181	1.650	1.104	1.747	1.028	1.850
29	1.341	1.483	1.270	1.563	1.198	1.650	1.124	1.743	1.050	1.841
30	1.352	1.489	1.284	1.567	1.214	1.650	1.143	1.739	1.071	1.833
31	1.363	1.496	1.297	1.570	1.229	1.650	1.160	1.735	1.090	1.825
32	1.373	1.502	1.309	1.574	1.244	1.650	1.177	1.732	1.109	1.819
33	1.383	1.508	1.321	1.577	1.258	1.651	1.193	1.730	1.127	1.813
34	1.393	1.514	1.333	1.580	1.271	1.652	1.208	1.728	1.144	1.808
35	1.402	1.519	1.343	1.584	1.283	1.653	1.222	1.726	1.160	1.803
36	1.411	1.525	1.354	1.587	1.295	1.654	1.236	1.724	1.175	1.799
37	1.419	1.530	1.364	1.590	1.307	1.655	1.249	1.723	1.190	1.795
38	1.427	1.535	1.373	1.594	1.318	1.656	1.261	1.722	1.204	1.792
39	1.435	1.540	1.382	1.597	1.328	1.658	1.273	1.722	1.218	1.789
40	1.442	1.544	1.391	1.600	1.338	1.659	1.285	1.721	1.230	1.786
45	1.475	1.566	1.430	1.615	1.383	1.666	1.336	1.720	1.287	1.776
50	1.503	1.585	1.462	1.628	1.421	1.674	1.378	1.721	1.335	1.771
55	1.528	1.601	1.490	1.641	1.452	1.681	1.414	1.724	1.374	1.768
60	1.549	1.616	1.514	1.652	1.480	1.689	1.444	1.727	1.408	1.767
65	1.567	1.629	1.536	1.662	1.503	1.696	1.471	1.731	1.438	1.767
70	1.583	1.641	1.554	1.672	1.525	1.703	1.494	1.735	1.464	1.768
75	1.598	1.652	1.571	1.680	1.543	1.709	1.515	1.739	1.487	1.770
80	1.611	1.662	1.586	1.688	1.560	1.715	1.534	1.743	1.507	1.772
85	1.624	1.671	1.600	1.696	1.575	1.721	1.550	1.747	1.525	1.774
90	1.635	1.679	1.612	1.703	1.589	1.726	1.566	1.751	1.542	1.776
95	1.645	1.687	1.623	1.709	1.602	1.732	1.579	1.755	1.557	1.778
100	1.654	1.694	1.634	1.715	1.613	1.736	1.592	1.758	1.571	1.780
150	1.720	1.746	1.706	1.760	1.693	1.774	1.679	1.788	1.665	1.802
200	1.758	1.778	1.748	1.789	1.738	1.799	1.728	1.810	1.718	1.820



الجدول 6 تابع : إحصاءة داربين-واتسون بمستوى معنوية 5 %

n	k'=6		k'=7		k'=8		k'=9		k'=10	
	dL	dU	dL	dU	dL	dU	dL	dU	dL	dU
6	---	---	---	---	---	---	---	---	---	---
7	---	---	---	---	---	---	---	---	---	---
8	---	---	---	---	---	---	---	---	---	---
9	---	---	---	---	---	---	---	---	---	---
10	---	---	---	---	---	---	---	---	---	---
11	0.203	3.005	---	---	---	---	---	---	---	---
12	0.268	2.832	0.171	3.149	---	---	---	---	---	---
13	0.328	2.692	0.230	2.985	0.147	3.266	---	---	---	---
14	0.389	2.572	0.286	2.848	0.200	3.111	0.127	3.360	---	---
15	0.447	2.472	0.343	2.727	0.251	2.979	0.175	3.216	0.111	3.438
16	0.502	2.388	0.398	2.624	0.304	2.860	0.222	3.090	0.155	3.304
17	0.554	2.318	0.451	2.537	0.356	2.757	0.272	2.975	0.198	3.184
18	0.603	2.257	0.502	2.461	0.407	2.667	0.321	2.873	0.244	3.073
19	0.649	2.206	0.459	2.396	0.456	2.589	0.396	2.783	0.290	2.974
20	0.692	2.162	0.595	2.339	0.502	2.521	0.416	2.704	0.336	2.885
21	0.732	2.124	0.637	2.290	0.547	2.460	0.461	2.633	0.380	2.806
22	0.769	2.090	0.677	2.246	0.588	2.407	0.504	2.571	0.424	2.734
23	0.804	2.061	0.715	2.208	0.628	2.360	0.545	2.514	0.465	2.670
24	0.837	2.035	0.751	2.174	0.666	2.318	0.584	2.464	0.506	2.613
25	0.868	2.012	0.784	2.144	0.702	2.318	0.621	2.419	0.544	2.560
26	0.897	1.992	0.816	2.117	0.735	2.246	0.657	2.379	0.581	2.513
27	0.925	1.974	0.845	2.093	0.767	2.216	0.691	2.342	0.616	2.470
28	0.951	1.958	0.874	2.071	0.798	2.188	0.723	2.309	0.650	2.431
29	0.975	1.944	0.900	2.052	0.826	2.164	0.753	2.278	0.682	2.396
30	0.998	1.931	0.926	2.034	0.854	2.141	0.782	2.251	0.712	2.363
31	1.020	1.920	0.950	2.018	0.879	2.120	0.810	2.226	0.741	2.333
32	1.041	1.909	0.972	2.004	0.904	2.102	0.836	2.203	0.769	2.306
33	1.061	1.900	0.994	1.991	0.927	2.085	0.861	2.181	0.795	2.281
34	1.080	1.891	1.015	1.979	0.950	2.069	0.885	2.162	0.821	2.257
35	1.097	1.884	1.034	1.967	0.971	2.054	0.908	2.144	0.845	2.236
36	1.114	1.877	1.053	1.957	0.991	2.041	0.930	2.127	0.868	2.216
37	1.131	1.870	1.071	1.948	1.011	2.029	0.951	2.112	0.891	2.198
38	1.146	1.864	1.088	1.939	1.029	2.017	0.970	2.098	0.912	2.180
39	1.161	1.859	1.104	1.932	1.047	2.007	0.990	2.085	0.932	2.164
40	1.175	1.854	1.120	1.924	1.064	1.997	1.008	2.072	0.945	2.149
45	1.238	1.835	1.189	1.895	1.139	1.958	1.089	2.002	1.038	2.088
50	1.291	1.822	1.246	1.875	1.201	1.930	1.156	1.989	1.110	2.044
55	1.334	1.814	1.294	1.861	1.253	1.909	1.212	1.959	1.170	2.010
60	1.372	1.808	1.335	1.850	1.298	1.894	1.260	1.939	1.222	1.984
65	1.404	1.805	1.370	1.843	1.336	1.882	1.301	1.923	1.266	1.964
70	1.433	1.802	1.401	1.837	1.369	1.873	1.337	1.910	1.305	1.948
75	1.458	1.801	1.428	1.834	1.399	1.867	1.369	1.901	1.339	1.935
80	1.480	1.801	1.453	1.831	1.425	1.861	1.397	1.893	1.369	1.925
85	1.500	1.801	1.474	1.829	1.448	1.857	1.422	1.886	1.396	1.916
90	1.518	1.801	1.494	1.827	1.469	1.854	1.445	1.881	1.420	1.909
95	1.535	1.802	1.512	1.827	1.489	1.852	1.465	1.877	1.442	1.903
100	1.550	1.803	1.528	1.826	1.506	1.850	1.484	1.874	1.462	1.898
150	1.651	1.817	1.637	1.832	1.622	1.847	1.608	1.862	1.594	1.877
200	1.707	1.831	1.697	1.841	1.686	1.852	1.675	1.863	1.665	1.874



جدول 7 : إحصاءة Wallis بمستوى معنوية 5 % لمحدرات غير محتوية على متغيرات وهمية وموسمية  $k=k'+1$

n	k'=1		k'=2		k'=3		k'=4		k'=5	
	d4,L	d4,U	d4,L	d4,U	d4,L	d4,U	d4,L	d4,U	d4,L	d4,U
16	0.774	0.982	0.662	1.109	0.549	1.275	0.435	1.381	0.350	1.532
20	0.924	1.102	0.827	1.203	0.728	1.327	0.626	1.428	0.544	1.556
24	1.036	1.189	0.953	1.273	0.867	1.371	0.779	1.459	0.702	1.565
28	1.123	1.257	1.050	1.328	0.975	1.410	0.898	1.487	0.828	1.576
32	1.192	1.311	1.127	1.373	1.061	1.443	0.993	1.511	0.929	1.587
36	1.248	1.355	1.191	1.410	1.131	1.471	1.070	1.532	1.013	1.598
40	1.295	1.392	1.243	1.442	1.190	1.496	1.135	1.550	1.082	1.609
44	1.335	1.423	1.288	1.469	1.239	1.518	1.189	1.567	1.141	1.620
48	1.369	1.451	1.326	1.493	1.281	1.537	1.236	1.582	1.191	1.630
52	1.399	1.475	1.359	1.513	1.318	1.554	1.276	1.595	1.235	1.639
56	1.426	1.496	1.389	1.532	1.351	1.569	1.312	1.608	1.273	1.648
60	1.449	1.515	1.415	1.548	1.379	1.583	1.343	1.619	1.307	1.656
64	1.470	1.532	1.438	1.563	1.405	1.596	1.371	1.629	1.337	1.664
68	1.489	1.548	1.459	1.577	1.427	1.608	1.396	1.639	1.364	1.671
72	1.507	1.562	1.478	1.589	1.448	1.618	1.418	1.648	1.388	1.678
76	1.522	1.574	1.495	1.601	1.467	1.628	1.439	1.656	1.411	1.685
80	1.537	1.586	1.511	1.611	1.484	1.637	1.457	1.663	1.431	1.691
84	1.550	1.597	1.525	1.621	1.500	1.646	1.475	1.671	1.449	1.696
88	1.562	1.607	1.539	1.630	1.515	1.654	1.490	1.677	1.466	1.702
92	1.574	1.617	1.551	1.639	1.528	1.661	1.505	1.684	1.482	1.707
96	1.584	1.626	1.563	1.647	1.541	1.668	1.519	1.690	1.496	1.712
100	1.594	1.634	1.573	1.654	1.552	1.674	1.531	1.695	1.510	1.717



جدول 8 : إحصاءة Wallis بمستوى معنوية 5 % لمحدرات محتوية على متغيرات وهمية وموسمية  $k=k''+4$

n	k''=1		k''=2		k''=3		k''=4		k''=5	
	d4,L	d4,U	d4,L	d4,U	d4,L	d4,U	d4,L	d4,U	d4,L	d4,U
16	1.156	1.381	1.031	1.532	0.902	1.776	0.777	2.191	0.693	2.238
20	1.228	1.428	1.123	1.556	1.013	1.726	0.899	1.954	0.806	2.042
24	1.287	1.459	1.199	1.565	1.107	1.694	1.011	1.856	0.928	1.949
28	1.337	1.487	1.261	1.576	1.181	1.679	1.099	1.803	1.025	1.889
32	1.379	1.511	1.312	1.587	1.243	1.673	1.171	1.773	1.104	1.850
36	1.414	1.532	1.355	1.598	1.293	1.672	1.230	1.755	1.170	1.824
40	1.445	1.550	1.391	1.609	1.336	1.674	1.279	1.745	1.225	1.807
44	1.471	1.567	1.422	1.620	1.373	1.677	1.321	1.739	1.272	1.795
48	1.494	1.582	1.450	1.630	1.404	1.681	1.357	1.737	1.312	1.788
52	1.514	1.595	1.474	1.639	1.432	1.686	1.389	1.736	1.347	1.782
56	1.533	1.608	1.495	1.648	1.456	1.691	1.416	1.736	1.377	1.779
60	1.549	1.619	1.514	1.656	1.478	1.696	1.441	1.737	1.404	1.777
64	1.564	1.629	1.531	1.664	1.497	1.700	1.463	1.739	1.429	1.776
68	1.577	1.639	1.546	1.671	1.515	1.705	1.482	1.741	1.450	1.775
72	1.590	1.648	1.560	1.678	1.531	1.710	1.500	1.743	1.470	1.776
76	1.601	1.656	1.573	1.685	1.545	1.714	1.517	1.746	1.488	1.776
80	1.611	1.663	1.585	1.691	1.559	1.719	1.531	1.748	1.504	1.777
84	1.621	1.671	1.596	1.696	1.571	1.723	1.545	1.751	1.519	1.778
88	1.630	1.677	1.607	1.702	1.582	1.727	1.558	1.753	1.533	1.779
92	1.639	1.684	1.616	1.707	1.593	1.731	1.570	1.756	1.546	1.781
96	1.647	1.690	1.625	1.712	1.603	1.735	1.580	1.759	1.558	1.782
100	1.654	1.695	1.633	1.717	1.612	1.739	1.591	1.761	1.569	1.784



## قائمة المراجع

- 1- BRIDGE . J.L "Applied Econometrics",  
North - Holland publishing Company, Amsterdam 1971.
- 2- BRILLET.J.L "Modelisation Econometrique": Principes et  
Techniques, Economica, Paris 1994.
- 3- CHALLEN .D.W and HAGGER.A.J "Macroeconometric  
Systems: Construction, Validation and Applications" Mac  
Millan Press L.T.D, London 1983.
- 4- CHOW .G.C "Econometric Analysis by Control Methods"  
John Wiley and Sons, New York 1981.
- 5- CHOW .G.C "Econometrics", Mc Graw-Hill, London, 1983.
- 6- COMON.M.S "Basis Econometrics" , John Weilley,  
London 1971.
- 7- DAGNELIE.P "Theorie et Methodes statistiques",  
Volume1,2. Les presses Agronomiques de Gembloux (A.S.B.L)  
Belgique 1984.
- 8- DAVID .G.M "Applications of Econometrics", prentice Hall  
International INC, London 1981.
- 9- DEATON. A. and MUELBAUER.J. "Economics and  
Consumer Behavior", Cambridge University Press, 1980.
- 10- DHRYMES.P.J "Introductory Econometrics", Springer  
Verlay, New York, 1971 and 1978.
- 11- DORNBUSH.R and FISHER.S "Macroeconomics",  
MAC Graw-Hill Company, London 1994.

**12- FARRAR.D.E and GLAUBER.R.R. "Multicollinearity in Regression Analysis" Revue of Economics and Statistics, Vol 49, 1967.**

**13- GODFREY.L.G "Misspecification Tests in Econometrics" Cambridge University Press, 1990.**

**14- GOLDBERGER.A.S "Econometric Theory" John Wiley and Sons, Inc, New York, 1964.**

**15- GOURIEROUX.C et MONFORT.A "Statistique et Modeles Econometriques", Volume 1,2, Economica, Paris 1989.**

**16- GRANGER.C.W.J and NEWBOLD.P "Forecasting Economic Time Series" Academic Press, Inc, London 1986.**

**17- HARVEY.A.C "The Econometric Analysis of Time Series", Philip Alan, Oxford 1981.**

**18- HOUTHAKKER.H and TAYLOR.L "Consumer Demand in the USA 1929-1970", Analysis and Projections Harvard Univeristy Press, USA, 1970.**

**19- INTRILIGATOR.M.D "Econometric Models and Applications" Mc-Craw-Hill Company, London 1978.**

**20- JOHNSTON.J. "Econometric Methods", Mc-Craw-Hill International Book Company, London 1984.**

**21- JUDGE.G.G., GRIFFITHS.W.E, Hill.R.C and LEE.T.C "The Theory and Practice of Econometrics", Wiley, New York, 1980.**

**22- KELEJIAN.H.H. and OATES.WE. "Introduction to**



**Econometrics", Second edition, Harpper International Edition, London 1976.**

**23- KMENTA.J. "Elements of Econometrics", Collier-Mac Millan Publishers, London 1971.**

**24- KMENTA.J. and RAMSEY.J.B. "Evaluation of Econometric Models" Academic Press, London, 1980.**

**25- KOUTSOYIANNIS.A. "Theory of Econometrics", Mc Millan Press. LTD, London 1983.**

**26- LUCAS.R. and SARGENT.T. "Rational Expectations and Econometric Practice", George Allen, London 1981.**

**27- LÜTKERPHOL.H. "Introduction to Multiple Time Series Analysis", Springer-Verlag, Berlin, 1991.**

**28- MADDALA.G.S. "Econometrics", Mc Craw-Hill New York 1971.**

**29- MADDALA.G.S "Introduction to Econometrics", Mac Millan Publishing Company, New York, 1988.**

**30- MALINVAUD.E "Statistical Methods of Econometrics" North-Holland Publishing Company, 1970.**

**31- PINDYCK.R.S and RUBINFELD.D.L. "Econometric Models and Economic Forecasts", Mc-Craw-Hill Interenational Book Company, London 1981.**

**32- POLLOCK.D.S.G. "The Algebra of Econometrics", John Weiley and Sons. LTD, 1979.**

- 33- SCHMIDT.P. "Econometrics" Marcel Delaken, New York, 1976.
- 34- SPANOS.A. "Statistical Foundations of Econometric Modelling", Cambridge University Press, 1986.
- 35- STEWART.J. "Econometrics", Cambridge University Press, 1991.
- 36- STEWART.J. and WALLIS.K.F. "Introductory Econometrics" Basil Black-Well, Oxford 1981.
- 37- STIGLER.J.M. "Gauss and the Invention of Least Squares", The Annals of statistics, Vol 9, N°3, 1981.
- 38- THEIL.H. "Principles of Econometrics", John Wiley and Sons, New York, 1971.
- 39- WALLIS.K.F. "Topics in Applied Econometrics" Basil Black-Well, Oxford, 1979.
- 40- WONNACOTT.T. and WONNACOTT.R. "Introductory statistics", John Willey and Sons, London 1977 and 1979.

أنجز طبعه على مطابع

ديوان المطبوعات الجامعية  
الساحة المركزية - بن عكنون  
الجزائر